



**HAL**  
open science

# Prévision du Dynamic Line Rating et impact sur la gestion du système électrique

Romain Dupin

► **To cite this version:**

Romain Dupin. Prévision du Dynamic Line Rating et impact sur la gestion du système électrique. Energie électrique. Université Paris sciences et lettres, 2018. Français. NNT : 2018PSLEM021 . tel-02149342

**HAL Id: tel-02149342**

**<https://pastel.hal.science/tel-02149342>**

Submitted on 6 Jun 2019

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# THÈSE DE DOCTORAT

de l'Université de recherche Paris Sciences et Lettres  
PSL Research University

Préparée à MINES ParisTech

Prévision du Dynamic Line Rating et Impact sur la Gestion  
du Système Electrique

**Ecole doctorale n°432**

SCIENCES DES METIERS DE L'INGENIEUR

**Spécialité** Energétique et Procédés

**Soutenue par Romain DUPIN**  
**le 03 juillet 2018**

Dirigée par **George KARINIOTAKIS**  
Et **Andréa MICHIORRI**

## COMPOSITION DU JURY :

**M. Nouredine HADJSAID,**  
Grenoble INP, Président

**M. Pierre PINSON,**  
Technical University of Denmark,  
Rapporteur

**M. Manuel MATOS**  
INESC TEC, Rapporteur

**M. Julio USAOLA,**  
Universidad Carlos III de Madrid,  
Rapporteur

**M. Vera PAIVA DA SLIVA,**  
EDF Lab Paris-Saclay, Membre du jury

**M. Paul PENSERINI,**  
RTE, Membre du jury

**M. George KARINIOTAKIS,**  
MINES ParisTech, Membre du jury

**M. Andréa MICHIORRI,**  
MINES ParisTech, Membre du jury





# Remerciements professionnels

---

Au terme du travail de ce doctorat, plusieurs institutions sont à remercier pour leur participation à mes travaux de thèse.

Tout d'abord, les entreprises Red Electrica et Northern Ireland Electricity (NIE), qui m'ont fourni des données de stations météorologiques collectées pour des périodes de plusieurs mois sur des dispositifs Dynamic Line Rating (DLR), et qui m'ont permis de travailler sur le développement de mes modèles de prévision du DLR. Un remerciement aussi à Météo France, des données collectées sur une de leur station météorologique ayant été utilisée.

Ces modèles de prévision ont aussi nécessité des données historiques de prévisions météorologiques pour leur développement, et je remercie ici le Centre Européen pour les Prévisions Météorologiques à Moyen terme (ECMWF) qui me les a fournies.

Les différentes approches qui ont été développées ont été inspirées de travaux faits lors d'un échange auprès de l'institut de recherche INESC TEC, en particulier grâce à l'aide précieuse de Laura Cavalcante et de Ricardo Bessa. Cet échange a été permis par une aide financière fournie par le projet européen FP7 Electra développé au sein de la *European Energy Research Alliance* (EERA).

Enfin, je remercie MINES ParisTech, l'institution qui m'a encadré lors de ce doctorat, ainsi que Georges Kariniotakis, mon directeur de thèse, et Andréa Michiorri, mon maître de thèse, qui m'ont soutenu tout le long de mes travaux.



# Sommaire

---

<b>Remerciements professionnels</b>	<b>IV</b>
<b>Sommaire</b>	<b>VI</b>
<b>Liste des figures</b>	<b>X</b>
<b>Liste des tableaux</b>	<b>XVI</b>
<b>Liste des sigles utilisés</b>	<b>XVIII</b>
<b>1. Introduction - Le Dynamic Line Rating et sa prévision</b>	<b>20</b>
<b>1.1. Le réseau électrique et les problématiques associées</b>	<b>20</b>
<b>1.2. Définition du Dynamic Line Rating</b>	<b>22</b>
1.2.1. Les différentes limites de courant dans les lignes électriques aériennes	22
1.2.2. Du Static Line Rating vers le Dynamic Line Rating	24
1.2.3. La technologie du DLR	25
1.2.4. Projets impliquant le DLR – une utilisation principalement sur les lignes à haute tension	26
<b>1.3. Lien entre le RTLR et les observations météorologiques</b>	<b>27</b>
1.3.1. Equations mécaniques liant la flèche de la ligne et sa température	28
1.3.2. Equation de chaleur pour la définition de l'intensité maximale de courant admissible	29
1.3.3. Sensibilité du DLR aux paramètres météorologiques	33
1.3.4. Considérations sur la section critique de la ligne	34
<b>1.4. Bénéfices de l'utilisation du DLR</b>	<b>35</b>
1.4.1. Une réduction des coûts de l'électricité	35
1.4.2. Implantation facilitée pour les énergies éoliennes	37
1.4.3. Amélioration de la fiabilité du réseau	39
1.4.4. Une technologie prometteuse nécessitant des prévisions	40
<b>1.5. Etat de l'art des méthodes de prévision du DLR</b>	<b>40</b>
1.5.1. Généralités sur les prévisions DLR	40
1.5.2. Modèles de prévisions du DLR	42
1.5.3. Discussion sur l'état de l'art des modèles de prévision du DLR	47
<b>1.6. Utilisation des prévisions dans des planifications de production d'électricité</b>	<b>48</b>
1.6.1. Utilisation de niveaux de probabilité fixés	48
1.6.2. Optimisations stochastiques prenant en compte le DLR	49
<b>1.7. Objectifs et démarche de la thèse</b>	<b>50</b>
<b>1.8. Structure du manuscrit</b>	<b>52</b>
<b>2. Prévision du Dynamic Line Rating à court-terme</b>	<b>54</b>
<b>2.1. Introduction</b>	<b>54</b>
<b>2.2. Cas d'étude</b>	<b>55</b>
2.2.1. Définition du Static Line Rating	55
2.2.2. Section critique de la ligne	57

<b>2.3.</b>	<b>Propositions de modèles de prévision probabilistes</b>	<b>58</b>
2.3.1.	Description des modèles	58
2.3.2.	Evaluation des modèles de prévision	64
2.3.3.	Variables explicatives utilisées	69
2.3.4.	Classement des variables	74
<b>2.4.</b>	<b>Sensibilité des modèles au paramétrage</b>	<b>78</b>
2.4.1.	Sensibilité du QLR au paramétrage	78
2.4.2.	Sensibilité du MDNN au paramétrage	80
2.4.3.	Sensibilité du KDE au paramétrage	81
2.4.4.	Sensibilité du QRF au paramétrage	83
2.4.5.	Sensibilité du GBRT au paramétrage	85
<b>2.5.</b>	<b>Evaluation des modèles</b>	<b>87</b>
2.5.1.	Evaluation des modèles sur des critères déterministes	90
2.5.2.	Evaluation des modèles sur des critères probabilistes	90
2.5.3.	Indice d'évaluation des prévisions probabilistes	96
<b>2.6.</b>	<b>Conclusions</b>	<b>98</b>
<b>3.</b>	<b><i>Modélisation de la partie basse des distributions</i></b>	<b>100</b>
<b>3.1.</b>	<b>Introduction – Du besoin de prévisions extrêmes</b>	<b>100</b>
<b>3.2.</b>	<b>Modélisation de la partie basse à partir d'une seule prévision probabiliste</b>	<b>102</b>
3.2.1.	Méthodologie	102
3.2.2.	Résultats	104
3.2.3.	Discussion	105
<b>3.3.</b>	<b>Modélisation de la partie basse à partir d'un ensemble d'observations et de prévisions probabilistes</b>	<b>106</b>
3.3.1.	Interpolation exponentielle	106
3.3.2.	Partitionnement en k-moyennes	107
3.3.3.	Evaluation – fiabilité des prévisions à très bas quantile	112
3.3.4.	Evaluation – finesse et scores quantiles	116
<b>3.4.</b>	<b>Conclusions</b>	<b>118</b>
<b>4.</b>	<b><i>Vers une sélection dynamique des Prévisions du Dynamic Line Rating</i></b>	<b>120</b>
<b>4.1.</b>	<b>Introduction</b>	<b>120</b>
<b>4.2.</b>	<b>Choix et présentation du sujet d'étude</b>	<b>121</b>
4.2.1.	Choix du sujet d'étude	121
4.2.2.	Cadre relatif à la définition de la capacité d'échange transfrontalière	122
<b>4.3.</b>	<b>Méthodologie</b>	<b>123</b>
4.3.1.	Description du sujet d'étude	123
4.3.2.	Définition de la fonction objectif	125
<b>4.4.</b>	<b>Remarques sur les coûts pour le gestionnaire de réseau</b>	<b>127</b>
<b>4.5.</b>	<b>Cas d'étude</b>	<b>129</b>
4.5.1.	Prévisions DLR	129
4.5.2.	Coûts Spot et coûts d'équilibrage	130
<b>4.6.</b>	<b>Résultats</b>	<b>131</b>
<b>4.7.</b>	<b>Conclusions</b>	<b>135</b>

## **5. Impact des prévisions du Dynamic Line Rating sur la gestion d'un réseau électrique** **136**

<b>5.1. Introduction</b>	<b>136</b>
<b>5.2. Méthodologie</b>	<b>137</b>
5.2.1. Forme générale du problème : problème d'optimisation stochastique	138
5.2.2. Description de la fonction objectif	138
<b>5.3. Problème d'optimisation stochastique</b>	<b>141</b>
5.3.1. Problème – Hypothèse de monopole verticalement intégré	141
5.3.2. Problème– Ajout de l'aversion au risque	143
<b>5.4. Méthode de résolution</b>	<b>146</b>
5.4.1. Hypothèses et simplifications	146
5.4.2. Description des outils	147
<b>5.5. Cas d'étude</b>	<b>151</b>
5.5.1. Description du réseau utilisé	151
5.5.2. Tables de correspondance obtenues	152
5.5.3. Cas d'étude 1 : séries temporelles réelles	154
5.5.4. Cas d'étude 2 : séries générées par bootstrap	155
5.5.5. Différences de calcul pour les deux cas d'étude	156
<b>5.6. Résultats pour le cas 1</b>	<b>157</b>
5.6.1. Evaluation de la stratégie neutre au risque	157
5.6.2. Evaluation des stratégies averses au risque	159
<b>5.7. Résultats pour le cas 2</b>	<b>162</b>
5.7.1. Utilisation de stratégies neutres au risque	162
5.7.2. Utilisation de fonctions de pertes différentes	164
5.7.3. Utilisation de modèles de prévision différents	168
5.7.4. Utilisation d'un modèle de prévision avec une partie basse de distribution remodelisée	170
<b>5.8. Conclusions</b>	<b>178</b>
<b>6. Conclusions</b>	<b>180</b>
<b>6.1. Conclusions générales et contributions</b>	<b>180</b>
<b>6.2. Perspectives</b>	<b>183</b>
6.2.1. Améliorations possibles de la description du problème d'optimisation stochastique	183
6.2.2. Pistes d'amélioration des modèles de prévision	184
<b>7. Liste des publications</b>	<b>186</b>
<b>8. Bibliographie</b>	<b>188</b>
<b>Annexe 1 - R. Dupin, A. Michiorri, G. Kariniotakis, "Dynamic Line Rating Day-Ahead Forecasts – Cost Benefit Based Selection of the Optimal Quantile", CIREN workshop, 2016, Helsinki.</b>	<b>198</b>
<b>Annexe 2 - F. Teng, R. Dupin, A. Michiorri, G. Kariniotakis, Y. Chen, and G. Strbac, 'Understanding the Benefits of Dynamic Line Rating under Multiple Sources of Uncertainty', IEEE Trans. Power Syst., 2017.</b>	<b>204</b>

***Annexe 3 - R. Dupin, A. Michiorri, G. Kariniotakis, 'Optimal Dynamic Line Rating Forecasts Selection Based on Ampacity Probabilistic Forecasting and Network Operators' Risk Aversion', IEEE Trans. Power Syst., 2018. \_\_\_\_\_ 216***

# Liste des figures

---

<b>FIGURE 1-1.</b> CARTE DES LIGNES HAUTE ET TRÈS HAUTE TENSION EN EUROPE [3].....	20
<b>FIGURE 1-2.</b> ILLUSTRATION DE LA COURBE DE ST. CLAIR [18]. .....	23
<b>FIGURE 1-3.</b> EXEMPLE DE VARIATIONS DE LIMITES DE COURANTS DUES À DES CONTRAINTES THERMIQUES (COURBES EN POINTILLÉ) OU À DES CONTRAINTES DE TENSION (COURBES CONTINUES), EN FONCTION DE LA LONGUEUR D'UNE LIGNE CONSIDÉRÉE [19]. .....	23
<b>FIGURE 1-4.</b> EXEMPLES D'APPAREILS UTILISÉS POUR L'APPLICATION DU DLR : L'OUTIL THERMALRATE (A), L'OUTIL POWER DONUT (B), L'OUTIL CAT-1 (C), L'OUTIL SAGOMETER (D) ET L'OUTIL DÉVELOPPÉ PAR AMPACIMON (E).....	26
<b>FIGURE 1-5.</b> POUR UNE LIGNE ÉLECTRIQUE AÉRIENNE, SCHÉMA REPRÉSENTANT LA FLÈCHE (SAG) ET LA DISTANCE ENTRE LA LIGNE ET LES OBJETS EN-DESSOUS (CLEARANCE). .....	28
<b>FIGURE 1-6.</b> SCHÉMA DE COUPE TRANSVERSALE D'UNE LIGNE ÉLECTRIQUE. ....	30
<b>FIGURE 1-7.</b> EVOLUTION DE L'AMPACITÉ RÉELLE D'UNE LIGNE ÉLECTRIQUE AÉRIENNE EN FONCTION DE DIFFÉRENTS PARAMÈTRES MÉTÉOROLOGIQUES.....	34
<b>FIGURE 1-8.</b> VALEURS D'AMPACITÉ RÉELLE D'UNE LIGNE ÉLECTRIQUE AÉRIENNE FONCTION DU NIVEAU DE PRODUCTION ÉLECTRIQUE D'UNE FERME ÉOLIENNE SITUÉE À PROXIMITÉ [55].....	37
<b>FIGURE 1-9.</b> PROFITS FINANCIERS TOTAUX POUR UNE FERME ÉOLIENNE, EN FONCTION DU NOMBRE D'ÉOLIENNES INSTALLÉE, ET DE LA STRATÉGIE ASSOCIÉE À LA LIGNE CONNECTANT LA FERME AU RÉSEAU : PAS DE MODIFICATION DE LA LIGNE (SLR1), UTILISATION DU RENFORCEMENT (SLR2) ET UTILISATION DU DLR, EN NE CONSIDÉRANT QUE L'INFLUENCE DE LA TEMPÉRATURE AMBIANTE (DLR1), DU VENT (DLR2) OU DES DEUX PARAMÈTRES SIMULTANÉMENT (DLR3). .....	38
<b>FIGURE 1-10.</b> ILLUSTRATION DU MÉCANISME DE PRÉVISIONS AGRÉGÉES POUR LE DLR AVEC DES PRÉVISIONS PROBABILISTES POUR LES DIFFÉRENTS PARAMÈTRES MÉTÉOROLOGIQUES, ET UNE SIMULATION DE MONTE CARLO [85]. .....	44
<b>FIGURE 1-11.</b> ILLUSTRATION DE PRÉVISIONS DLR QUANTILE, AVEC UNE PROBABILITÉ D'ÊTRE SUPÉRIEURE À L'OBSERVATION FUTURE FIXÉE À 2,5%, TELLES QUE PRÉSENTÉES DANS [74] .....	49
<b>FIGURE 2-1.</b> SCHÉMA D'UN MODÈLE DE DENSITÉ MÉLANGE PARAMÉTRÉE PAR RÉSEAU DE NEURONES. ....	60
<b>FIGURE 2-2.</b> SCHÉMA DE FONCTIONNEMENT D'UN MODÈLE DE RÉGRESSION QUANTILE PAR FORÊT ALÉATOIRE. ....	62
<b>FIGURE 2-3.</b> ÉVOLUTIONS DES VALEURS DES SCORES QUANTILES EN FONCTION DES QUANTILES SÉLECTIONNÉS. LES PRÉVISIONS UTILISÉES SONT ISSUES DE MODÈLES PRÉSENTÉS DANS LE CHAPITRE 3. ....	67
<b>FIGURE 2-4.</b> ÉVOLUTION DES SCORES QUANTILES PONDÉRÉS, NORMALISÉS PAR RAPPORT AUX VALEURS DU SCORE GLOBAL OBTENU PAR LE CALCUL DE LA MOYENNE DES SCORES QUANTILES PONDÉRÉS. ....	68
<b>FIGURE 2-5.</b> REPRÉSENTATION D'UNE MAILLE DE PRÉVISIONS MÉTÉOROLOGIQUES ENCADRANT UNE STATION MÉTÉOROLOGIQUE (CROIX BLEUE). .....	72
<b>FIGURE 2-6.</b> AMÉLIORATION RELATIVE DES PRÉVISIONS FAITES À MIDI, EN FONCTION DE LA VARIABLE AJOUTÉE, MOYENNÉE SUR LES 8 STATIONS ÉTUDIÉES POUR DES HORIZONS DE PRÉVISION ALLANT DE 24 HEURES À 48 HEURES. ....	73
<b>FIGURE 2-7.</b> AMÉLIORATION RELATIVE DES PRÉVISIONS FAITES À MIDI, EN FONCTION DE LA VARIABLE AJOUTÉE, MOYENNÉE SUR LES 8 STATIONS ÉTUDIÉES POUR DES HORIZONS DE PRÉVISION ALLANT DE 24 HEURES À 31 HEURES, ET DE 41 HEURES À 48 HEURES (SEULES LES PRÉVISIONS EN JOURNÉE, DE 7H00 À 17H00, SONT CONSIDÉRÉES). .....	74

<b>FIGURE 2-8.</b> EVOLUTION DU CRPS, DE QSMOY(1%,20%), QSMOY(1%,5%) ET QS1% POUR DES PRÉVISIONS FOURNIES PAR DES MODÈLES QLR DIFFÉRENTS À DES HORIZONS DE 24 HEURES ET MOYENNÉS SUR LES 8 STATIONS CONSIDÉRÉES, AVEC DES NOMBRES DE VARIABLE DIFFÉRENTS. LES CERCLES ROUGES REPRÉSENTENT LES MINIMUMS DES DIFFÉRENTES COURBES.....	79
<b>FIGURE 2-9.</b> EVOLUTION DES SCORES QUANTILES DES PRÉVISIONS DLR FOURNIES AVEC UN QLR, POUR UN HORIZON DE 24 HEURES ET MOYENNÉ SUR LES 8 STATIONS CONSIDÉRÉES, EN FONCTION DU NOMBRE DE VARIABLES ET DU PERCENTILE SÉLECTIONNÉ. LE CODE COULEUR SUIVANT EST UTILISÉ : VERT FONCÉ POUR LES SOLUTIONS OPTIMALES, VERT CLAIR POUR LES COMBINAISONS ENTRAÎNANT UNE DÉGRADATION DU SCORE QUANTILE INFÉRIEURE À 5%, JAUNE POUR UNE DÉGRADATION COMPRISE ENTRE 5% ET 10% ET ROUGE POUR UNE DÉGRADATION SUPÉRIEURE À 10%.....	80
<b>FIGURE 2-10.</b> COMPARAISON DU CRPS ET DU QSMOY(1%,20%) POUR DIFFÉRENTS MODÈLES DE KDE ENTRAÎNÉS À DES HORIZONS DE 24 HEURES ET MOYENNÉS SUR LES 8 STATIONS CONSIDÉRÉES, AVEC UN NOMBRE ARBITRAIRE DE VARIABLES SÉLECTIONNÉES AVEC L'ALGORITHME GLOUTON ET LA PCA, ET UN PARAMÈTRE DE LISSAGE OBTENU SOIT PAR LA MÉTHODE DE SILVERMANN, SOIT PAR UNE VALIDATION CROISÉE.....	82
<b>FIGURE 2-11.</b> COMPARAISON DU CRPS DU QSMOY(1%,20%) POUR DIFFÉRENTS MODÈLES DE KDE ENTRAÎNÉS À DES HORIZONS DE 24 HEURES ET MOYENNÉS SUR LES 8 STATIONS CONSIDÉRÉES, AVEC UN NOMBRE ARBITRAIRE DE VARIABLES SÉLECTIONNÉES AVEC L'ALGORITHME GLOUTON ET LA PCA, ET UN PARAMÈTRE DE LISSAGE OBTENU PAR LA MÉTHODE DE SILVERMANN OU UNE VALIDATION CROISÉE.....	83
<b>FIGURE 2-12.</b> COMPARAISON DES ÉVOLUTIONS DU CRPS ET DU QSMOY(1%,20%) POUR DIFFÉRENTS MODÈLES DE QRF ENTRAÎNÉS À DES HORIZONS DE 24 HEURES ET MOYENNÉS SUR LES 8 STATIONS CONSIDÉRÉES, AVEC UN NOMBRE ARBITRAIRE DE VARIABLES SÉLECTIONNÉES AVEC L'ALGORITHME GLOUTON ET LA PCA.....	84
<b>FIGURE 2-13.</b> EVOLUTION DES SCORES QUANTILES DES PRÉVISIONS DLR FOURNIES AVEC UN QRF, POUR UN HORIZON DE 24 HEURES ET MOYENNÉ SUR LES 8 STATIONS CONSIDÉRÉES, EN FONCTION DU NOMBRE DE VARIABLES ET DU PERCENTILE SÉLECTIONNÉ. LE CODE COULEUR UTILISÉ EST LE MÊME QUE SUR LA <b>FIGURE 2-9</b> .....	85
<b>FIGURE 2-14.</b> COMPARAISON DU CRPS DU QSMOY(1%,20%) POUR DIFFÉRENTS MODÈLES DE GBRT ENTRAÎNÉS À DES HORIZONS DE 24 HEURES ET MOYENNÉS SUR LES 8 STATIONS CONSIDÉRÉES, AVEC UN NOMBRE ARBITRAIRE DE VARIABLES SÉLECTIONNÉES AVEC L'ALGORITHME GLOUTON.....	86
<b>FIGURE 2-15.</b> EVOLUTION DES SCORES QUANTILES DES PRÉVISIONS DLR FOURNIES AVEC UN GBRT, POUR UN HORIZON DE 24 HEURES ET MOYENNÉS SUR LES 8 STATIONS CONSIDÉRÉES, EN FONCTION DU NOMBRE DE VARIABLES ET DU PERCENTILE SÉLECTIONNÉ. LE CODE COULEUR UTILISÉ EST LE MÊME QUE SUR LA <b>FIGURE 2-9</b> .....	87
<b>FIGURE 2-16.</b> COMPARAISON DE L'ÉVOLUTION DU MAPE POUR DIFFÉRENTS MODÈLES DE PRÉVISION DE TYPE QRF, FOURNISSANT DES PRÉVISIONS POUR LES 8 STATIONS CONSIDÉRÉES ET POUR DES HORIZONS ALLANT DE 1 À 48 HEURES.....	88
<b>FIGURE 2-17.</b> EXEMPLE DE PRÉVISIONS RTLR POUR LA STATION MÉTÉO 1, POUR UNE PÉRIODE ALLANT DU 24/04/2010 AU 02/05/2010, FOURNIES AVEC UN QLR (A), UN MDNN (B), UN KDE (C), UN QRF (D) ET UN GRBT (E). LES PRÉVISIONS SONT FAITES TOUS LES JOURS À 12H00, POUR DES HORIZONS DE PRÉVISION ALLANT DE 24 HEURES À 47 HEURES.....	89
<b>FIGURE 2-18.</b> COMPARAISON DE L'ÉVOLUTION DU MAPE POUR DIFFÉRENTS MODÈLES DE PRÉVISION, FOURNIS AVEC LES 5 MÉTHODOLOGIES CONSIDÉRÉES ET UN MODÈLE PERSISTANCE. LES INDICES SONT CALCULÉS EN FAISANT LA MOYENNE DES MAPE OBSERVÉS POUR LES 8 STATIONS DIFFÉRENTES, POUR DES HORIZONS DE PRÉVISION ALLANT DE 1 À 48 HEURES.....	90
<b>FIGURE 2-19.</b> DIAGRAMMES PIT POUR LES 5 DIFFÉRENTS MODÈLES CONSIDÉRÉS. POUR CALCULER LA FIABILITÉ, ON CONSIDÈRE LA FRÉQUENCE RELATIVE DES PRÉVISIONS ASSOCIÉES AUX FRÉQUENCES CONSIDÉRÉES SUPÉRIEURES AUX OBSERVATIONS, CE POUR L'ENSEMBLE DES PRÉVISIONS FAITES SUR LES 8 STATIONS DIFFÉRENTES, AVEC DES HORIZONS ALLANT DE 24 À 48 HEURES. ON REPRÉSENTE AVEC LES BARRES D'ERREUR LES ÉCARTS-TYPES ASSOCIÉS AUX VARIATIONS DE VALEURS DE FIABILITÉ ENTRE LES DIFFÉRENTES STATIONS. SUR LA <b>FIGURE 2-19.A</b> , ON REPRÉSENTE LES DIAGRAMMES PIT POUR LES QUANTILES ALLANT DE 0 À 100%, ET SUR LA <b>FIGURE 2-19.B</b> , LES DIAGRAMMES PIT POUR LES QUANTILES ALLANT DE 0 À 20%.....	93

<b>FIGURE 2-20.</b> DIAGRAMMES PIT POUR DES PRÉVISIONS FOURNIES PAR 2 DIFFÉRENTS MODÈLES DE GBRT, AVEC LES MÊMES CONSIDÉRATIONS QUE SUR LA <b>FIGURE 2-19</b> . SUR LE DIAGRAMME DE GAUCHE, LE MODÈLE EST ENTRAÎNÉ À L'AIDE D'UN ÉCHANTILLON D'ENTRAÎNEMENT FIXE, COMPRENANT DES DONNÉES COLLECTÉES SUR UNE ANNÉE. POUR LE DEUXIÈME À DROITE, LE MODÈLE EST ENTRAÎNÉ AVEC DES ÉCHANTILLONS D'ENTRAÎNEMENT RÉACTUALISÉS TOUS LES MOIS, EN UTILISANT UNE FENÊTRE GLISSANTE CORRESPONDANT À UNE ANNÉE DE DONNÉES.....	94
<b>FIGURE 2-21.</b> TAILLE MOYENNE DES INTERVALLES [ $Y_{TK} + H TK3\%$ , $Y_{TK} + H TK97\%$ ] POUR DIFFÉRENTS MODÈLES DE PRÉVISION, FOURNIS AVEC LES 5 MÉTHODOLOGIES CONSIDÉRÉES. LES INDICES SONT CALCULÉS EN FAISANT LA MOYENNE DES MAPE OBSERVÉS POUR LES 8 STATIONS DIFFÉRENTES, POUR DES HORIZONS DE PRÉVISION ALLANT DE 1 À 48 HEURES. ....	94
<b>FIGURE 2-22.</b> FRÉQUENCE DE SITUATIONS OÙ $Y_{TK} + H TK3\% \geq SLR$ POUR DIFFÉRENTS MODÈLES DE PRÉVISION, FOURNIS AVEC LES 5 MÉTHODOLOGIES CONSIDÉRÉES. LES INDICES SONT CALCULÉS EN FAISANT LA MOYENNE DES MAPE OBSERVÉS POUR LES 8 STATIONS DIFFÉRENTES, POUR DES HORIZONS DE PRÉVISION ALLANT DE 1 À 48 HEURES. ....	95
<b>FIGURE 2-23.</b> COMPARAISON DE L'ÉVOLUTION DU CRPS, DE $QSMOY(1\%,20\%)$ ET DE $QSMOY(1\%,5\%)$ POUR DIFFÉRENTS MODÈLES DE PRÉVISION, FOURNIS AVEC LES 5 MÉTHODOLOGIES CONSIDÉRÉES. LES INDICES SONT CALCULÉS EN FAISANT LA MOYENNE DES MAPE OBSERVÉS POUR LES 8 STATIONS DIFFÉRENTES, POUR DES HORIZONS DE PRÉVISION ALLANT DE 1 À 48 HEURES.....	97
<b>FIGURE 3-1.</b> DIAGRAMME PIT CRÉÉ DE LA MÊME MANIÈRE QUE CEUX PRÉSENTÉS SUR LA <b>FIGURE 2-19</b> , AVEC 6 STATIONS DIFFÉRENTES, FAIT POUR DES PRÉVISIONS GÉNÉRÉES AVEC UN MODÈLE QRF, AVEC UN CHANGEMENT D'ÉCHELLE DE MANIÈRE À NE MONTRER L'ÉVOLUTION DE LA FIABILITÉ QUE POUR LES QUANTILES ALLANT DE 0,1% À 2%. ....	101
<b>FIGURE 3-2.</b> DIAGRAMMES PIT CRÉÉS DE LA MÊME MANIÈRE QUE CEUX PRÉSENTÉS SUR LA <b>FIGURE 2-19</b> , FAITS POUR DES PRÉVISIONS GÉNÉRÉES AVEC UN MODÈLE QRF, AVEC UNE MODIFICATION D'ÉCHELLE DE MANIÈRE À NE MONTRER L'ÉVOLUTION DE LA FIABILITÉ QUE POUR LES QUANTILES ALLANT DE 0,1% À 2%. SUR LA <b>FIGURE 3-2.A</b> , LE MODÈLE UTILISÉ EST UN QRF NON MODIFIÉ ; SUR LA <b>FIGURE 3-2.B</b> , LE MODÈLE UTILISÉ EST UN QRF MODIFIÉ AVEC LA MÉTHODOLOGIE PROPOSÉE, INDÉPENDAMMENT DE LA VALEUR DE $\Gamma$ ; SUR LA <b>FIGURE 3-2.C</b> , LE MODÈLE UTILISÉ EST UN QRF MODIFIÉ AVEC LA MÉTHODOLOGIE PROPOSÉE, LES MODIFICATIONS N'ÉTANT FAITES QUE SI $\Gamma > 0$ . ....	105
<b>FIGURE 3-3.</b> FINESSE DES PRÉVISIONS, ICI REPRÉSENTÉE PAR LA DIFFÉRENCE ENTRE UNE PRÉVISION À 95% ET UNE PRÉVISION À 5%, EN FONCTION DES VALEURS DES PRÉVISIONS RTLR MÉDIANES POUR LA STATION 1, CE POUR DES HORIZONS DE PRÉVISION ALLANT DE 24 À 47 HEURES POUR LA PÉRIODE DE L'ANNÉE 2010. ....	108
<b>FIGURE 3-4.</b> SCHÉMAS ILLUSTRANT UNE MÉTHODE DE K-VALIDATION CROISÉE EN HAUT, AVEC $k=12$ , ET UNE MÉTHODE D'ENTRAÎNEMENT AVEC FENÊTRE GLISSANTE EN BAS.....	110
<b>FIGURE 3-5.</b> EXEMPLES DE CLUSTERING FAITS SUR DES PRÉVISIONS FAITES SUR LA STATION 1, POUR DES HORIZONS DE PRÉVISIONS ALLANT DE 24 À 30 HEURES. 4 CLUSTERS SONT CONSIDÉRÉS SUR LA <b>FIGURE 3-5.A</b> ET 10 SUR LA <b>FIGURE 3-5.B</b> . POUR CHAQUE CLUSTER, ON MONTRÉ SUR LA FIGURE LA VALEUR DE P OBTENUE.....	111
<b>FIGURE 3-6.</b> EXEMPLE DE PRÉVISIONS RTLR POUR LA STATION MÉTÉO 1, FOURNIES AVEC UN QRF NON MODIFIÉ (A), UN QRF MODIFIÉ AVEC DES QUEUES EXPONENTIELLES DONT LES PARAMÈTRES SONT ASSOCIÉS À 5 CLUSTERS FAITS SUR LES COUPLES DE QUANTILES (5%,10%) (B) ET UN QRF MODIFIÉ AVEC DES QUEUES EXPONENTIELLES DONT LES PARAMÈTRES SONT ASSOCIÉS À 10 CLUSTERS FAITS SUR LES COUPLES DE QUANTILES (5%,10%) (C). ....	113
<b>FIGURE 3-7.</b> ÉVOLUTION DE LA FRÉQUENCE RELATIVE D'ÉVÉNEMENTS OÙ DES PRÉVISIONS RTLR QUANTILES À 0,1%, 0,2%, 0,5% ET 1,0% SONT SUPÉRIEURES À DES OBSERVATIONS, MOYENNÉES POUR LES 6 STATIONS MÉTÉOROLOGIQUES CONSIDÉRÉES ET POUR DES HORIZONS ALLANT DE 24 À 47 HEURES, POUR DES MODÈLES DE QRF DONT LES PARTIES BASSES DES DISTRIBUTIONS SONT MODIFIÉES AVEC DES INTERPOLATIONS LINÉAIRES AUX PARAMÈTRES FIXÉS EN FONCTION DE L'APPARTENANCE À DES CLUSTERS DONNÉS. ON DÉFINIT LE NOMBRE DE CES CLUSTERS DE MANIÈRE VARIABLE, ALLANT DE 1 À 15 CLUSTERS. ....	114
<b>FIGURE 3-8.</b> DIAGRAMMES PIT CRÉÉS DE LA MÊME MANIÈRE QUE CEUX PRÉSENTÉS SUR LA <b>FIGURE 2-19</b> , FAITS POUR DES PRÉVISIONS GÉNÉRÉES AVEC UN MODÈLE QRF, AVEC UN CHANGEMENT D'ÉCHELLE DE MANIÈRE À NE MONTRER L'ÉVOLUTION DE LA FIABILITÉ QUE POUR LES QUANTILES ALLANT DE 0,1% À 2%. LES FIGURES A ET B REPRÉSENTENT LES MÊMES RÉSULTATS, À L'EXCEPTION DE L'ÉCHELLE	

SUR L'AXE DES ORDONNÉES QUI EST MODIFIÉE. LES FIGURES 1 CORRESPONDENT À UN MODÈLE N'AYANT PAS ÉTÉ MODIFIÉ, LES FIGURES 2 À UN MODÈLE MODIFIÉ MAIS OÙ IL N'Y A PAS EU DE CLUSTERING ET UN SEUL PARAMÈTRE P EST CONSIDÉRÉ, LES FIGURES 3 UN MODÈLE OÙ LA MÉTHODOLOGIE EST UTILISÉE AVEC 4 CLUSTERS, ET LES FIGURES 4 UN MODÈLE OÙ 10 CLUSTERS ONT ÉTÉ UTILISÉS. .... 115

**FIGURE 3-9.** EVOLUTION DE LA FRÉQUENCE RELATIVE D'ÉVÉNEMENTS OÙ DES PRÉVISIONS RTLR QUANTILES À 0,1%, 0,2%, 0,5% ET 1,0% SONT SUPÉRIEURES À DES OBSERVATIONS, MOYENNÉES POUR LES 6 STATIONS MÉTÉOROLOGIQUES CONSIDÉRÉES ET POUR DES HORIZONS ALLANT DE 24 À 47 HEURES, POUR DES MODÈLES DE QRF DONT LES PARTIES BASSES DES DISTRIBUTIONS SONT MODIFIÉES AVEC DES INTERPOLATIONS LINÉAIRES AUX PARAMÈTRES FIXÉS EN FONCTION DE L'APPARTENANCE À DES CLUSTERS DONNÉS. ON DÉFINIT LE NOMBRE DE CES CLUSTERS DE MANIÈRE VARIABLE, ALLANT DE 1 À 15 CLUSTERS. .... 116

**FIGURE 3-10.** EVOLUTION RELATIVE DE LA VALEUR MOYENNE DES SCORES QUANTILES ALLANT DE 1% À 5%, MOYENNÉE POUR LES 6 STATIONS MÉTÉOROLOGIQUES CONSIDÉRÉES ET POUR DES HORIZONS ALLANT DE 24 À 47 HEURES, POUR DES MODÈLES DE QRF DONT LES PARTIES BASSES DES DISTRIBUTIONS SONT MODIFIÉES AVEC DES INTERPOLATIONS LINÉAIRES AUX PARAMÈTRES FIXÉS SUIVANT L'APPARTENANCE À DES CLUSTERS DONNÉS. ON DÉFINIT LE NOMBRE DE CES CLUSTERS DE MANIÈRE VARIABLE, ALLANT DE 1 À 15 CLUSTERS. CES CLUSTERS SONT DÉFINIS EN FONCTION DE PRÉVISIONS RTLR QUANTILE POUR DES COUPLES (T1, T2) DIFFÉRENTS.. 117

**FIGURE 4-1.** SCHEMA DES DEUX MARCHES D'ELECTRICITE CONSIDERES. .... 124

**FIGURE 4-2.** EXEMPLE DE L'ÉVOLUTION DE LA TTC AVEC L'AMPACITÉ D'UNE LIGNE INITIALEMENT CONGESTIONNÉE, POUR LA CAS PROPOSÉ DANS [133]. A NOTER QUE POUR UNE VALEUR DE DLR INFÉRIEURE À 100%, ON A CONSIDÉRÉ SUR CETTE FIGURE QUE LA VALEUR DU SLR ÉTAIT ALORS UTILISÉE EN PRATIQUE SUR LA LIGNE. .... 125

**FIGURE 4-3.** RÉSUMÉ DES GAINS (EN VERT) ET DES PERTES FINANCIÈRES (EN ROUGE) ASSOCIÉES À L'UTILISATION DE PRÉVISIONS DLR, POUR UN MONOPOLE VERTICALEMENT INTÉGRÉ OU CONSIDÉRANT UNE SÉPARATION ENTRE LES DIFFÉRENTS ACTEURS DU RÉSEAU... 129

**FIGURE 4-4.** OBSERVATIONS DLR ET PRÉVISIONS PROBABILISTES POUR LE CAS CONSIDÉRÉ, AVEC DES PRÉVISIONS FAITES TOUS LES JOURS À 12H00 ET DES HORIZONS DE PRÉVISIONS ALLANT DE 24 À 47 HEURES..... 130

**FIGURE 4-5.** DIAGRAMMES PIT POUR DES NIVEAUX DE PROBABILITÉ DE 0%-100% ET 0%-20%. .... 130

**FIGURE 4-6.** EVOLUTION DU SW EN FONCTION DE QUANTILES FIXÉS ENTRE 1% ET 99%. LA VALEUR DE BÉNÉFICES DE 100% CORRESPOND À L'UTILISATION DE PRÉVISIONS PARFAITES..... 132

**FIGURE 4-7.** EVOLUTION DES REVENUS D'UN PRODUCTEUR D'ÉNERGIE PHOTOVOLTAÏQUE EN FONCTION DE QUANTILES ARBITRAIREMENT SÉLECTIONNÉS ENTRE 1% ET 99%. LA VALEUR DE BÉNÉFICES DE 100% CORRESPOND À L'UTILISATION DE PRÉVISIONS PARFAITES... 133

**FIGURE 4-8.** EVOLUTION DES COÛTS ASSOCIÉS AUX ACTIVATIONS DE RÉSERVE DUES AUX ERREURS DE PRÉVISIONS DLR, EN FONCTION DES BÉNÉFICES EN TERMES DE BIEN-ÊTRE SOCIAL OBTENUS PAR L'UTILISATION DE LA LIGNE. EN BLEU, SONT REPRÉSENTÉS LES STRATÉGIES À QUANTILE FIXES ; EN ROUGE LES POINTS ASSOCIÉS À DES STRATÉGIES DE QUANTILES SAISONNIERS ; EN BLANC LE POINT ASSOCIÉ À L'UTILISATION DU SLR ET EN JAUNE LE POINT ASSOCIÉ À DES PRÉVISIONS DYNAMIQUES AVEC UNE CONNAISSANCE PARFAITE DES PRIX À L'AVANCE. .... 134

**FIGURE 5-1.** RÉSEAU IEEÉ À 24 NŒUDS. EN ROUGE, ON SURLIGNE LES LIGNES ÉQUIPÉES DE DLR EN ROUGE..... 152

**FIGURE 5-2.** VALEUR D'AMPACITÉ REQUISE DANS LES LIGNES 8-9 ET 8-10 POUR LEVER LES CONGESTIONS DANS CES LIGNES, EN FONCTION DES NIVEAUX DE CONSOMMATIONS L1 ET L2 DANS LES ZONES 1 ET 2. LES CASES BLANCHES CORRESPONDENT À DE SITUATIONS OÙ APRÈS DCOFF, IL N'Y A PAS DE CONGESTION, ET LES CASES ROUGES AUX SITUATIONS OÙ DES CONGESTIONS APPARAISSENT DANS LES LIGNES ÉQUIPÉES DE DLR. LES VALEURS D'AMPACITÉ REQUISES POUR LEVER LES CONGESTIONS SONT NORMALISÉES PAR RAPPORT AUX VALEURS DE SLR..... 153

**FIGURE 5-3.** EN FONCTION DES DIFFÉRENTES STRATÉGIES UTILISÉES, ÉVOLUTION DES BÉNÉFICES OBTENUS PAR RAPPORT AUX BÉNÉFICES ATTENDUS. .... 160

**FIGURE 5-4.** EVOLUTION DES COÛTS DE RÉSERVE EN FONCTION DES BÉNÉFICES OBSERVÉS ET DE LA STRATÉGIE DE SÉLECTION DU DLR. LE POINT JAUNE CORRESPOND AU RÉSULTAT LIÉ À L'UTILISATION DE QUANTILES FIXÉS À 1%, ET LE POINT VIOLET À L'UTILISATION DE QUANTILES FIXÉS À 3%. .... 161

<b>FIGURE 5-5.</b> EVOLUTION DES FRÉQUENCES DE SITUATIONS OÙ DES ACTIVATIONS DE RÉSERVE AU COÛT SUPÉRIEUR À 60€ SONT NÉCESSAIRES, EN FONCTION DES BÉNÉFICES. LE POINT JAUNE CORRESPOND AU RÉSULTAT LIÉ À L'UTILISATION DE QUANTILES FIXÉS À 1%, ET LE POINT VIOLET À L'UTILISATION DE QUANTILES FIXÉS À 3%.....	162
<b>FIGURE 5-6.</b> EN FONCTION DES DIFFÉRENTES STRATÉGIES UTILISÉES, ÉVOLUTION DES BÉNÉFICES OBTENUS PAR RAPPORT AUX BÉNÉFICES ATTENDUS. SUR LA FIGURE DU HAUT, POUR LES ORDONNÉES, LA MÊME ÉCHELLE QUE SUR LA <b>FIGURE 5-3</b> EST UTILISÉE.....	165
<b>FIGURE 5-7.</b> EVOLUTION DES COÛTS DE RÉSERVE EN FONCTION DES BÉNÉFICES OBSERVÉS ET DE LA STRATÉGIE DE SÉLECTION DU DLR. LE POINT JAUNE CORRESPOND AU RÉSULTAT LIÉ À L'UTILISATION DE QUANTILES FIXÉS À 1%. .....	166
<b>FIGURE 5-8.</b> EVOLUTION DES FRÉQUENCES DE SITUATIONS OÙ DES ACTIVATIONS DE RÉSERVE AU COÛT SUPÉRIEUR À 1000€ ET 1500€ SONT NÉCESSAIRES, EN FONCTION DES BÉNÉFICES. LES POINTS JAUNES CORRESPONDENT AUX RÉSULTATS LIÉS À L'UTILISATION DE QUANTILES FIXÉS À 1%. .....	167
<b>FIGURE 5-9.</b> EVOLUTION DES COÛTS DE RÉSERVE EN FONCTION DES BÉNÉFICES OBSERVÉS ET DE LA STRATÉGIE DE SÉLECTION DU DLR. LA STRATÉGIE DE SÉLECTION DE LA PRÉVISION DLR OPTIMALE EST UNE STRATÉGIE D'OPTIMISATION AVERSE AU RISQUE, LA FONCTION DE PÉNALITÉ VB UTILISÉE ÉTANT UNE FONCTION LINÉAIRE. ....	168
<b>FIGURE 5-10.</b> EVOLUTION DES COÛTS DE RÉSERVE EN FONCTION DES BÉNÉFICES OBSERVÉS ET DE LA STRATÉGIE DE SÉLECTION DU DLR. LES POINTS CORRESPONDENT À L'UTILISATION DE QUANTILES FIXÉS À 1%, EN JAUNE AVEC LE MODÈLE QRF NON MODIFIÉ ET EN BLEU AVEC LES MODÈLES MODIFIÉS.....	173
<b>FIGURE 5-11.</b> EVOLUTION DES FRÉQUENCES DE SITUATIONS OÙ DES ACTIVATIONS DE RÉSERVE AU COÛT SUPÉRIEUR À 1000€ ET 1500€ SONT NÉCESSAIRES, EN FONCTION DES BÉNÉFICES. LES POINTS CORRESPONDENT À L'UTILISATION DE QUANTILES FIXÉS À 1%, EN JAUNE AVEC LE MODÈLE QRF NON MODIFIÉ ET EN BLEU AVEC LES MODÈLES MODIFIÉS.....	173
<b>FIGURE 5-12.</b> EVOLUTION DES COÛTS DE RÉSERVE EN FONCTION DES BÉNÉFICES OBSERVÉS ET DE LA STRATÉGIE DE SÉLECTION DU DLR. LE POINT JAUNE CORRESPOND À L'UTILISATION DE QUANTILES FIXÉS À 1% AVEC LE MODÈLE QRF NON MODIFIÉ.....	176
<b>FIGURE 5-13.</b> EVOLUTION DES FRÉQUENCES DE SITUATIONS OÙ DES ACTIVATIONS DE RÉSERVE AU COÛT SUPÉRIEUR À 1000€ ET 1500€ SONT NÉCESSAIRES, EN FONCTION DES BÉNÉFICES. LES POINTS JAUNES CORRESPONDENT À L'UTILISATION DE QUANTILES FIXÉS À 1% AVEC LE MODÈLE QRF NON MODIFIÉ. ....	176
<b>FIGURE 5-14.</b> EVOLUTION DES COÛTS DE RÉSERVE EN FONCTION DES BÉNÉFICES OBSERVÉS ET DE LA STRATÉGIE DE SÉLECTION DU DLR. LE POINT JAUNE CORRESPOND À L'UTILISATION DE QUANTILES FIXÉS À 1% AVEC LE MODÈLE QRF NON MODIFIÉ.....	177
<b>FIGURE 5-15.</b> EVOLUTION DES FRÉQUENCES DE SITUATIONS OÙ DES ACTIVATIONS DE RÉSERVE AU COÛT SUPÉRIEUR À 1000€ ET 1500€ SONT NÉCESSAIRES, EN FONCTION DES BÉNÉFICES. LES POINTS JAUNES CORRESPONDENT À L'UTILISATION DE QUANTILES FIXÉS À 1% AVEC LE MODÈLE QRF NON MODIFIÉ. ....	177



# Liste des tableaux

---

<b>TABLEAU 1-1.</b> EXEMPLE DE VALEURS DE SLR , EN FONCTION DES SAISONS ET DES PARAMÈTRES MÉTÉOROLOGIQUES ASSOCIÉS. ____	25
<b>TABLEAU 1-2.</b> NOMBRE DE PROJETS RÉPERTORIÉS PAR ENTSO-E UTILISANT LE DLR, EN FONCTION DU NIVEAU DE TENSION ASSOCIÉ [30]. _____	27
<b>TABLEAU 1-3.</b> RELATION ENTRE GR·PR, A2 ET M2 _____	32
<b>TABLEAU 1-4.</b> RELATION ENTRE B1, N, RE ET RF _____	32
<b>TABLEAU 2-1.</b> CARACTÉRISTIQUES TECHNIQUES DU CÂBLE LYNX 175 MM <sup>2</sup> _____	55
<b>TABLEAU 2-2.</b> COMPARAISON POUR LA SÉLECTION DES VALEURS DU SLR : CAS A, UTILISATION DE VALEURS DE SLR FIXÉES À L'AIDE DE PARAMÈTRES CONTRAIGNANTS ARBITRAIREMENT SÉLECTIONNÉS ; CAS B, UTILISATION DE VALEURS DE SLR CHOISIES DE MANIÈRE À RESTER INFÉRIEURES AU RTLR 99% DU TEMPS _____	56
<b>TABLEAU 2-3.</b> FRÉQUENCE DES SITUATIONS OÙ L'AMPACITÉ CALCULÉE EN UNE STATION DONNÉE EST LA VALEUR MINIMALE OBTENUE POUR L'ENSEMBLE DES STATIONS. _____	57
<b>TABLEAU 2-4.</b> FORME DES FONCTIONS DE PONDÉRATION UTILISÉES POUR CRÉER DES INDICES DE SCORING DONNANT PLUS DE POIDS À DIFFÉRENTES PARTIES DE DISTRIBUTION. _____	67
<b>TABLEAU 2-5.</b> RÉCAPITULATIF DES 27 VARIABLES INITIALEMENT CHOISIES POUR ENTRAÎNER LES MODÈLES DE PRÉVISION. _____	71
<b>TABLEAU 2-6.</b> ORDRE DES VARIABLES SÉLECTIONNÉS PAR L'ALGORITHME GLOUTON, POUR DES PRÉVISIONS FAITES AVEC POUR UN HORIZON DE 24 HEURES POUR LA STATION 1. LES MODÈLES SONT ENTRAÎNÉS POUR ÊTRE UTILISÉS TOUS LES JOURS À MIDI. _____	76
<b>TABLEAU 2-7.</b> ILLUSTRATION DE L'INFLUENCE DES PARAMÈTRES DU MDNN SUR LES PERFORMANCES DU MODÈLE. LES CASES ROUGES REPRÉSENTE LES CONFIGURATIONS PERMETTANT D'AVOIR UNE VALEUR DE QSMOY(1%,20%) INFÉRIEUR À UN SEUIL DONNÉ, ICI 50A, LES CASES VERTES LES SITUATIONS OÙ LE CRPS EST INFÉRIEUR À UN SEUIL DONNÉ, ICI 52A, ET EN ORANGE LES SITUATIONS PERMETTANT DE RESPECTER LES DEUX CRITÈRES. _____	81
<b>TABLEAU 2-8.</b> EXEMPLE DE VALEURS DE $\alpha\tau_B$ , FONCTION DES NOMBRES DE PRÉVISIONS CONSIDÉRÉES. _____	91
<b>TABLEAU 4-1.</b> ÉVOLUTION DES PRIX DE L'ÉLECTRICITÉ MOYENS (€/MWH) SUR LES MARCHÉS FRANÇAIS (1) ET BELGE (2). LES VALEURS SONT CALCULÉES À PARTIR DES DONNÉES DE L'ANNÉE 2014, SEULES LES DONNÉES DE PRIX POUR MIDI ÉTANT CONSIDÉRÉES. ____	131
<b>TABLEAU 4-2.</b> GAIN EN TERMES DE SWNOR ET D'AUGMENTATION DU DLR. _____	134
<b>TABLEAU 5-1.</b> EXEMPLES DE COUPLES DE PAYS CONSIDÉRÉS POUR GÉNÉRER LES COURBES DE CONSOMMATION ET FRÉQUENCE DES SITUATIONS ENTRAÎNANT DES CONGESTIONS SUR LES LIGNE ÉQUIPÉES DE DLR DANS LE RÉSEAU IEEE ÉTUDIÉ. _____	156
<b>TABLEAU 5-2.</b> VALEURS DE SLR UTILISÉES POUR GÉNÉRER LES VALEURS D'AMPACITÉ, DÉFINIES DE TELLE MANIÈRES À ÊTRE SUPÉRIEURES AUX OBSERVATIONS DU RTLR 1% DU TEMPS. _____	156
<b>TABLEAU 5-3.</b> COMPARAISON DE STRATÉGIES : BÉNÉFICES ATTENDUS, BÉNÉFICES OBSERVÉS, FRÉQUENCE D'ACTIVATION DE RÉSERVE, COÛT TOTAL DE LA RÉSERVE, FRÉQUENCE DES SITUATIONS ENTRAÎNANT DES COÛTS DE RÉSERVE SUPÉRIEURS À 60€. _____	158
<b>TABLEAU 5-4.</b> COMPARAISON DE STRATÉGIES : BÉNÉFICES ATTENDUS, BÉNÉFICES OBSERVÉS, FRÉQUENCE D'ACTIVATION DE RÉSERVE, COÛT TOTAL DE LA RÉSERVE, FRÉQUENCE DES SITUATIONS ENTRAÎNANT DES COÛTS DE RÉSERVE SUPÉRIEURS À 1000€ ET 1500€. _	163
<b>TABLEAU 5-5.</b> À NIVEAUX DE BÉNÉFICES ÉGAUX, COMPARAISON DES COÛTS DE RÉSERVE GÉNÉRÉS AVEC L'UTILISATION DE MODÈLES DE PRÉVISION DIFFÉRENTS. _____	169

<b>TABLEAU 5-6.</b> DANS LE CADRE DE L'UTILISATION DE QUANTILES FIXÉS À 1%, COMPARAISON DE MODÈLES DE PRÉVISION DIFFÉRENTS.	171
<b>TABLEAU 5-7.</b> COMPARAISON DE L'UTILISATION DE MODÈLES DE PRÉVISION DIFFÉRENTS, POUR UN NIVEAU DE BÉNÉFICE FIXÉ À 0,61%.	172
<b>TABLEAU 5-8.</b> COMPARAISON DE L'UTILISATION DE MODÈLES DE PRÉVISION DIFFÉRENTS, POUR UN NIVEAU DE BÉNÉFICE FIXÉ À 0,61%.	174
<b>TABLEAU 6-1.</b> REPRISE DES RÉSULTATS DU <b>TABLEAU 5-4</b> : EXEMPLE DES MESURES DE BÉNÉFICES ET DES INDICES DE RISQUE AVEC LES STRATÉGIES ACTUELLES DES GRT, ET LES STRATÉGIES NEUTRES AU RISQUE PRÉSENTES DANS LA LITTÉRATURE	182

# Liste des sigles utilisés

---

ATC	Available Trading Capacity
CIGRE	Conseil International des Grands Réseaux Electriques
CRPS	Continuous Ranked Probability Score
DC	Direct Current
DCOPF	DC Optimal Power Flow
DCPF	DC power flow
DLR	Dynamic Line Rating
EENS	Expected Energy Not Supplied
EI	Exponential Interpolation
EnR	Energie Renouvelable
ECMWF	Centre européen pour les prévisions météorologiques à moyen terme
ENTSO-E	European Network of Transmission System Operators for Electricity – Association représentant 41 gestionnaires de réseau de transport européens.
ERDF	Électricité Réseau Distribution France – Ancien nom du gestionnaire de réseaux de distribution (maintenant appelée Enedis)
GBRT	Gradient boosting Regression Trees
KDE	Kernel Density Estimator
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MARS	Régression Multivariée par Spline Adaptative
MDNN	Mixture Density Neural Network
MI	Mutual Information
MPE	Mean Percentage Error
MSE	Mean Square Error
NIE Networks	<i>Northern Ireland Electricity Networks Limited</i> - gestionnaire des réseaux en Irlande du Nord
NOAA	National Oceanic and Atmospheric Administration
PCA	Principal Component Analysis

PIT	Probability Integral Transform
POT	Peak Over Threshold
QLR	Quantile Linear Regression
QRF	Quantile Regression Forest
QS	Quantile Score
RTE	Réseau de Transport d'Électricité – gestionnaire des réseaux de transport français
RTL	Real-Time Line Rating
SLR	Static Line Rating
SW	Social Welfare
TTC	Total Trading Capacity

# CHAPITRE 1

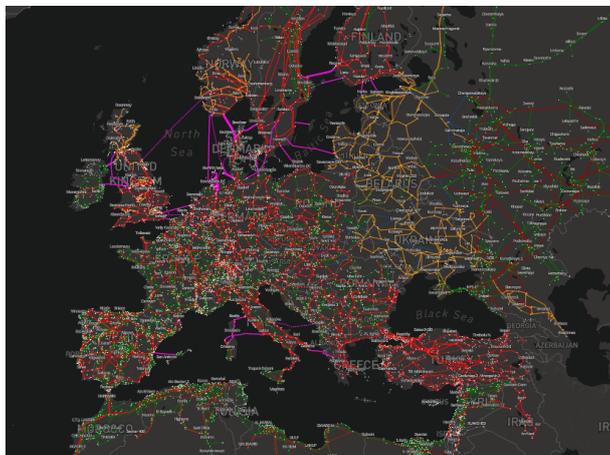
## Introduction - Le Dynamic Line Rating et sa prévision

---

### 1.1. Le réseau électrique et les problématiques associées

On définit le réseau électrique comme l'ensemble des infrastructures, lignes électriques et postes électriques permettant d'acheminer l'électricité des producteurs vers les consommateurs. Pour donner un ordre de grandeur de la taille de ce réseau électrique, le Réseau européen des gestionnaires de réseau de transport d'électricité (ENTSO-E) estimait en 2014 qu'il y avait 312693 km de lignes de transport pour le réseau européen, ayant permis d'acheminer 3174 TWh au cours de l'année [1] (**Figure 1-1**).

Sur ce réseau continental, les marchés électriques des différents pays sont fortement interconnectés entre eux. Ainsi, en 2014, ENTSO-E estimait que 423 TWh d'électricité étaient échangés entre les Gestionnaires de Réseau de Transport (GRT) membres, soit 13% du total de l'énergie transportée. Pour la France, en 2016, ces interconnexions avec les pays voisins permettaient d'importer une puissance moyenne de 9,8 GW, un chiffre que l'on peut comparer à la puissance consommée de 102 GW observée lors de la pointe de consommation record observée en France en 2012 [2].



**Figure 1-1.** Carte des lignes haute et très haute tension en Europe [3]

Cette structure de réseau est limitée par différentes contraintes. Nous en citerons quelques-unes, traditionnellement modélisées dans les problèmes de calcul de flux d'énergie :

1. Les valeurs de tension aux différents nœuds du réseau doivent être bornées. En France par exemple, les niveaux de tension doivent avoir des variations limitées entre 90% et 110% de la tension nominale au niveau des points de consommation [4].
2. En chaque instant, la production électrique et la consommation doivent être égales sur le réseau, pour permettre d'éviter des variations de fréquence en cas d'inégalité [5].
3. Les opérations de conduite réseau doivent être faites de manière à respecter des règles de sécurité tenant compte des défaillances possibles sur le réseau. Le critère N-1 est souvent mis en avant : en cas de défaillance d'un ouvrage sur le réseau, il est nécessaire que les consommateurs continuent d'être alimentés en électricité par des parties de réseau ou des unités de production autres [6].
4. Enfin, les courants passant dans les lignes électriques et les transformateurs doivent rester inférieurs à des valeurs seuil pour éviter des échauffements trop importants, des chutes de tension ou des effondrements de tension [7].

Ces différentes contraintes peuvent être plus ou moins limitatives, en fonction du dimensionnement du réseau électrique, et des enjeux importants y sont associés dans un contexte où les gestionnaires de réseau sont confrontés à des défis importants. Nous penserons ici à l'introduction des énergies renouvelables croissante, avec en particulier les deux sources d'énergies que sont l'éolien et le solaire. Depuis 2016, l'éolien est en effet devenu la deuxième forme d'énergie électrique du point de vue des capacités installées dans l'Union européenne, avec 153,7GW installés [8]. De manière similaire, la capacité de génération électrique d'origine photovoltaïque atteint aujourd'hui la valeur de 101,2GW, le niveau de capacité installée ayant plus que doublé depuis 2010 [8]. Ces quantités déjà relativement importantes seront encore amenées à croître, dans un contexte de transition énergétique où l'UE se fixe comme objectif à avoir d'abord 20% de sa consommation énergétique finale d'origine renouvelable en 2020 [9], puis 27% en 2030 [10]. Or, l'installation de ces énergies entraînent de nombreuses problématiques, comme par exemple le fait que ces installations sont majoritairement connectées sur des réseaux qui sont dimensionnés pour la distribution de l'énergie, et non la collecte.

Ainsi, dans une étude [11], Enedis, le gestionnaire de réseau de distribution français qui était alors appelé ERDF, avait cherché à estimer les coûts futurs de raccordement pour les énergies solaires, pour l'année 2030. Il y était montré que pour un coût de raccordement moyen de 300 k€/MW, à peu près 50% de ce coût était associé à des renforcements du réseau électrique, i.e. des remplacements de constituants n'étant alors pas en mesure de respecter les contraintes réglementaires car sous-dimensionnés.

On pourrait aussi souligner la déréglementation croissante des marchés de l'électricité faite en parallèle à un accroissement des échanges entre les différents marchés de l'électricité. Là aussi, les différentes contraintes du réseau électrique, ici les congestions, occasionnent des coûts importants en empêchant l'homogénéisation des coûts d'électricité entre les différents marchés. Une évaluation de ces coûts peut être faite grâce à l'observation de l'évolution de la rente de congestion payée au gestionnaire de réseau de transport français RTE, représentant les frais associés aux phénomènes de congestion limitant les échanges d'électricité entre la France et ses voisins, et qui est passée de 300 M€ en 2012 [12] à 475 M€ en 2015 [2].

Pour parer aux problèmes occasionnés dus aux contraintes du réseau, les mesures traditionnellement mises en place sont les renforcements et les extensions des réseaux électriques, avec par exemple des

opérations comme le remplacement ou la construction de lignes électriques. Or, de telles mesures peuvent être extrêmement coûteuses, et politiquement difficiles à mettre en place pour le cas de la construction de nouvelles lignes. Pour illustrer cette deuxième difficulté, nous prendrons l'exemple d'un projet de ligne aérienne franco-espagnole, proposé en 1980, et pour lequel il aura fallu 30 ans pour pouvoir commencer le chantier de la ligne, finalement souterraine et au coût multiplié par 8 [13].

En raison de ces difficultés, les opérateurs du réseau électrique recherchent alors des solutions alternatives. Nous pourrions citer en exemple l'utilisation de nouveaux types d'architectures de réseaux comme des réseaux de distribution maillés [14], ou encore de nouvelles manières de gérer les productions actives et réactives des énergies renouvelables [15]. Dans le cadre du travail présenté dans ce document, nous proposons d'étudier en particulier l'une de ces solutions, le Dynamic Line Rating (DLR).

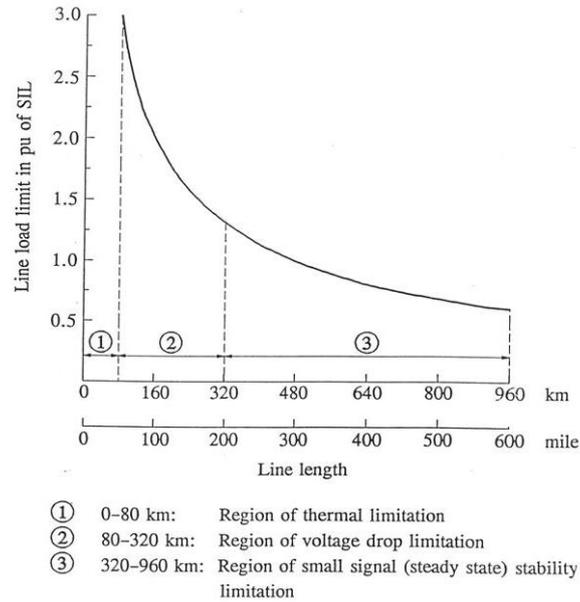
Dans la Section suivante, nous allons aborder les principes généraux de cette technologie et le modèle physique liant cette technologie à la météorologie. Par la suite, nous présenterons les bénéfices potentiels associés et les motivations pour le développement de prévisions du DLR. Cela sera suivi par un état de l'art sur les différentes méthodologies relatives au développement de prévisions DLR et sur l'utilisation faite de ces prévisions, de manière à illustrer les points manquants dans la littérature justifiant le travail ici présenté. Enfin, nous présenterons le plan du manuscrit de cette thèse.

## 1.2. Définition du Dynamic Line Rating

### 1.2.1. Les différentes limites de courant dans les lignes électriques aériennes

Le courant électrique pouvant passer dans une ligne électrique est toujours limité, pour des raisons de qualité et de sécurité. La nature du paramètre explicatif de cette limitation n'est pas unique, trois types de contraintes pouvant limiter les courants. De manière générale, nous tirons de la courbe de St. Clair [16] (**Figure 1-2**) que la nature de la contrainte dépend de la longueur de la ligne électrique:

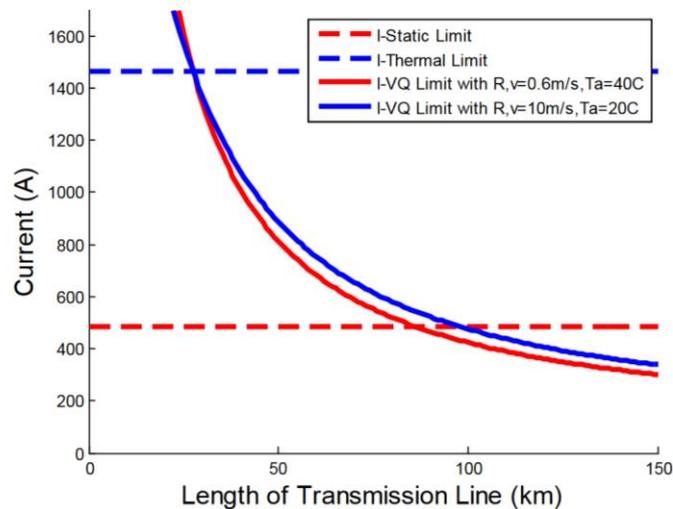
- La première contrainte est le fait que la température de la ligne doit rester inférieure à une certaine valeur maximale. Ce paramètre limite le courant dans des lignes de longueur inférieures à 80 km.
- Ensuite, le courant doit rester limité de manière que les chutes de tension restent bornées. Ce paramètre permet généralement de définir des limites de courants pour des lignes ayant une longueur allant de 80 km à 300 km.
- Enfin, une trop grande puissance transitant dans une ligne peut entraîner des phénomènes d'effondrement de tension [17]. Le courant passant dans des lignes longues de plus de 300 km est alors limité par des contraintes de stabilité pour éviter ces phénomènes.



**Figure 1-2.** Illustration de la courbe de St. Clair [18].

Il est ici intéressant de signaler que cette longueur de 80 km, définissant la limite entre les deux premières catégories de lignes, peut varier lorsque la définition des paramètres liés aux définitions des critères thermiques limitants évolue. Nous citerons [19], où l'évolution de l'ampacité thermique est mise en relation avec la limitation du courant maximal due aux limites de variations de tension, considérant des changements de caractéristiques climatiques pour définir l'ampacité.

Comme nous le voyons sur la **Figure 1-3**, le fait d'augmenter fortement l'ampacité thermique d'une ligne, d'une limite statique de 500A à une limite thermique de 1450A, implique des changements sur la nature des contraintes d'ampacité pour des distances variant entre 30km et 80 km, le paramètre de la chute de tension devenant le paramètre limitant pour cet intervalle de longueurs de ligne.



**Figure 1-3.** Exemple de variations de limites de courants dues à des contraintes thermiques (courbes en pointillé) ou à des contraintes de tension (courbes continues), en fonction de la longueur d'une ligne considérée [19].

## 1.2.2. Du Static Line Rating vers le Dynamic Line Rating

Dans cette thèse, nous nous intéressons principalement aux limites de courant associées aux contraintes thermiques, c'est-à-dire les limites de courant définies pour des lignes électriques de longueur inférieure à 50 km, ce pour des lignes électriques aériennes dans lesquelles un courant alternatif circule.

On définit tout d'abord le courant permanent admissible, aussi appelé ampacité, comme le courant maximal pouvant passer en régime permanent dans un conducteur, un dispositif ou un appareil de manière à ce que la température en régime permanent reste inférieure à un certain seuil dans des conditions données.

Pour les lignes souterraines, ces conditions sont principalement associées à la nature du sol et à sa capacité à absorber la chaleur [20]. Pour les lignes aériennes, les critères sont de nature météorologique, ceux-ci étant associés au vent, à l'irradiation solaire et à la température ambiante.

Ces valeurs d'ampacité sont généralement définies comme fixes. En raison de cet aspect statique, ces paramètres sont sélectionnés comme contraignants, de telle manière qu'il y ait une fréquence faible de situations présentant des conditions associées à des valeurs d'ampacité dynamiques plus faibles, et donc potentiellement dangereuses.

Pour donner un ordre de grandeur de la fréquence des situations où des conditions observées peuvent être plus contraignantes que les conditions considérées pour le calcul de l'ampacité, une valeur de 1% est recommandée par le Conseil International des Grands Réseaux Electriques (CIGRE) [21].

Certains proposent alors de sélectionner ces paramètres en observant les historiques des différentes variables météorologiques [22], et par la suite de sélectionner les valeurs d'ampacité de manière à respecter les critères de fréquence requis. En pratique, cependant, ces paramètres météorologiques contraignants sont souvent sélectionnés de manière arbitraire. Cela a pour conséquence que l'on observe régulièrement un non-respect de ce paramètre de fréquence de 1%, des valeurs de fréquences de dépassement allant jusqu'à 40% pouvant être observées dans certains cas d'étude [23], [24].

A partir des valeurs des paramètres météorologiques considérés, une ampacité peut être calculée avec un modèle physique d'équation de chaleur en régime permanent, généralement basée sur le modèle IEEE [25] ou le modèle CIGRE [26]. Cette valeur est alors utilisée en pratique pour définir le courant maximal et est désignée en anglais comme le Static Line Rating (SLR).

A titre d'exemple, des paramètres utilisés par l'opérateur de réseau nord-irlandais *Northern Ireland Electricity Networks Limited* (NIE Networks) [27], et les valeurs de SLR associées sont présentées sur le tableau 1.

Régulièrement, les lignes peuvent être congestionnées, le SLR étant trop bas par rapport à la valeur de courant que les opérateurs de réseau souhaiteraient faire passer dans une ligne électrique considérée. Si ces problèmes sont trop fréquents, comme on l'a déjà évoqué, il peut être décidé de construire une nouvelle ligne électrique, ou alors de remplacer les conducteurs de la ligne par des conducteurs plus adaptés à des valeurs de courant plus élevés.

Par rapport à ce deuxième point, plutôt que des câbles traditionnels *Aluminium Conductor Steel Reinforced* (ACSR), il peut alors être préféré d'utiliser des câbles *High Temperature Conductors* (HTC) qui permettent pour une température donnée de réduire fortement la déformation du câble. Ces câbles

HTC regroupent les catégories de câble *Aluminium Conductor Steel Supported (ACSS)*, *Aluminium Conductor Composite Core (ACCC)* et *Aluminium Conductor Steel Reinforced (ACSR)*.

**Tableau 1-1.** Exemple de valeurs de SLR , en fonction des saisons et des paramètres météorologiques associés.

	Température ambiante (°C)	Vitesse du vent (m/s)	Radiation solaire(W/m²)	Direction du vent (°)	Rating CIGRE (A)
Printemps/ Automne	9,0	0,5	0,0	90,0	623
Eté	20,0	0,5	0,0	90,0	574
Hiver	2,0	0,5	0,0	90,0	651

Cette solution du remplacement de la ligne ou du câble a le mérite d'une certaine simplicité, mais est associée aux inconvénients que l'on a évoqués précédemment, qui sont le coût et la difficulté de mise en œuvre de tels projets.

C'est pour proposer une alternative à ces difficultés qu'est alors développée une nouvelle approche pour calculer l'ampacité d'une ligne aérienne, pour la première fois dans [28]. L'idée présentée est de remplacer la méthodologie de sélection d'une ampacité statique par la sélection d'ampacités dynamiques, en accord avec des observations météorologiques faites sur le terrain. On parle alors de Real-Time Line Rating (RTL), correspondant à un instant donné au courant pouvant passer dans une ligne électrique sans qu'il n'y ait une élévation de température du câble trop importante. Cette valeur dépend alors de paramètres météorologiques mesurés, à l'inverse du SLR qui dépend de paramètres météorologiques fixes. En fonction de cette valeur de RTL, il est alors possible pour le gestionnaire de réseau de définir une nouvelle valeur d'ampacité de ligne, le Dynamic Line Rating (DLR). On signalera que le DLR est généralement différent du RTL en raison, par exemple, de limitations fixées par le gestionnaire de réseau sur les variations du DLR pour empêcher la possibilité d'incidents importants.

### 1.2.3. La technologie du DLR

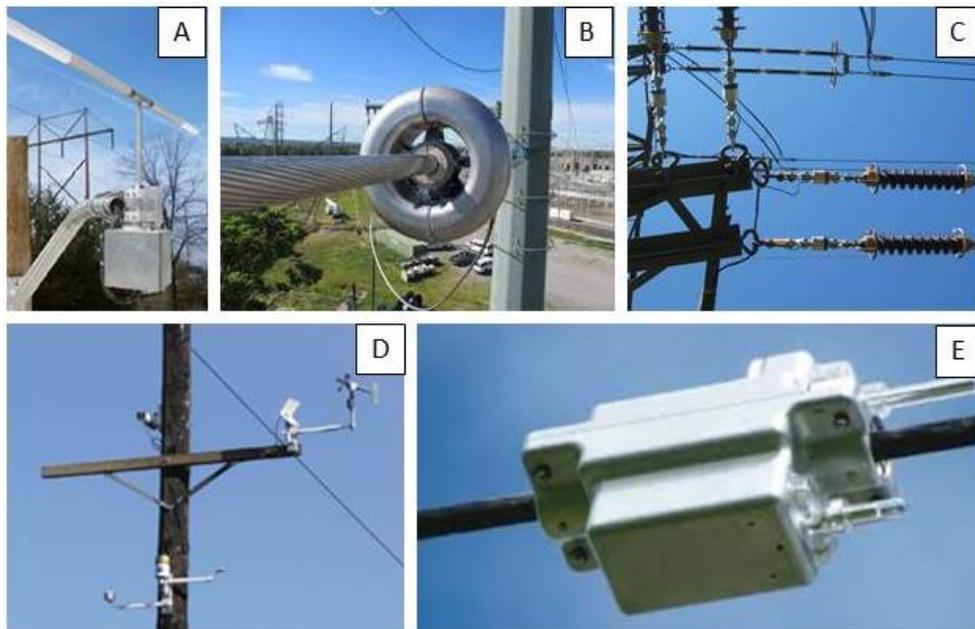
Les gestionnaires de réseau électrique témoignent un intérêt croissant pour cette méthodologie [29] [30], et dans ce contexte, différents dispositifs de mesure à mettre en place sur les lignes électriques sont aujourd'hui développés par des entreprises privées. Ces dispositifs sont variés dans leur fonctionnement, et on évoquera ici les principales catégories d'outils de mesure pour fournir un aperçu de cette diversité.

Le premier type d'outil de mesure est le plus simple. Il s'agit d'une mesure des différentes caractéristiques météorologiques en un point de la ligne faite avec une station météorologique. Un tel outil a l'avantage qu'il n'est pas nécessaire de l'installer sur une ligne électrique, et est simple dans son fonctionnement. Comme exemple d'une telle technologie, on peut citer un outil commercialisé par l'entreprise Pike, ThermalRate [31] (**Figure 1-4-A**). Avec cet outil, en un point de la ligne, il est à noter que la vitesse du vent est calculée et non mesurée : l'outil est constitué de deux conducteurs, l'un dans lequel du courant passe et l'autre où ce n'est pas le cas. Par la mesure de la différence de température des deux éléments, une vitesse de vent est calculée. Ce point est important, et se retrouvera sur l'ensemble des technologies que nous présenterons par la suite : la vitesse du vent peut être difficile à mesurer pour des vitesses inférieures à 1 m/s en raison d'un manque de fiabilité des anémomètres. Or autour de cette valeur de vitesse, par exemple en allant de 0 m/s à 1 m/s, le courant admissible dans la

ligne peut augmenter de manière significative, parfois de plus de 50%, et des mesures de la vitesse du vent précises sont alors nécessaires.

Une approche alternative est de calculer la vitesse du vent avec des mesures de caractéristiques de la ligne électrique. Les paramètres les plus fréquemment utilisés sont des mesures de la température de la ligne et du courant électrique. Le calcul de la vitesse du vent est ensuite fait de manière indirecte à partir de ces paramètres, d'autres critères météorologiques et du modèle physique liant la température du câble aux autres paramètres. Plusieurs technologies permettent ces mesures, celle du Power Donut développé dans les années 80 étant celle qui est la plus souvent mise en avant dans la littérature [32] (**Figure 1-4-B**).

On pourrait aussi évoquer d'autres paramètres de lignes utilisés pour la mesure du vent plus « exotiques » que la températures, comme la mesure de la tension mécanique de la ligne avec l'outil CAT-1 [33] (**Figure 1-4-C**), la flèche de la ligne avec le Sagometer [34] (**Figure 1-4-D**) ou encore la mesure de la vibration mécanique dans la ligne avec un outil développé par Ampacimon [35], [36] (**Figure 1-4-E**). Ces trois types de paramètre ont une caractéristique intéressante par rapport à la mesure de la température de la ligne ou du courant, c'est qu'il est représentatif du comportement de l'ensemble d'une section de ligne liant deux pylônes, là où la température est encore un paramètre local qui n'est valable que pour quelques mètres de la ligne.



**Figure 1-4.** Exemples d'appareils utilisés pour l'application du DLR : l'outil ThermalRate (A), l'outil Power Donut (B), l'outil CAT-1 (C), l'outil Sagometer (D) et l'outil développé par Ampacimon (E)

#### 1.2.4. Projets impliquant le DLR – une utilisation principalement sur les lignes à haute tension

Les technologies DLR sont aujourd'hui testées sur de nombreux projets. Il est ici intéressant de reprendre une étude faite par ENTSO-E [30], dans laquelle est fait un inventaire des différents projets de 15 GRT européens qui prennent en compte le DLR.

Parmi ces 15 GRT, 11 utilisent déjà le DLR dans leurs opérations, et 9 utilisent des prévisions météorologiques en plus d'autres méthodologies de mesure de température. Sur le **Tableau 1-2**, on a comptabilisé le nombre de projets incluant le DLR et répertoriés par ENTSO-E, en fonction des niveaux de tension associés. On peut constater que la plupart des applications sont sur des niveaux de tension élevés.

Les projets actuels prenant en compte des niveaux de tension plus bas sont relativement rares, comme par exemple [37] où le DLR est installé sur une ligne à 33kV. Pour illustrer cela, dans un état de l'art fait sur l'application du DLR pour l'introduction des énergies renouvelables [38], des énergies généralement installées sur des niveaux de tension HTA en France (de 1 à 50kV), on constate que l'ensemble des projets évoqués sont associés à des niveaux de tension allant de 66kV à 132kV.

Une raison à cela est le fait que le coût de la technologie DLR est encore important, de l'ordre de plusieurs dizaines de milliers d'euros pour certaines installations d'après les échanges que nous avons eu avec une entreprise spécialisée dans le DLR lors de ce doctorat. Dans ce contexte, la technologie est encore principalement utilisée sur des réseaux à haute tension où le rapport entre le coût et les bénéfices est beaucoup plus faible que sur les réseaux à tension plus basse.

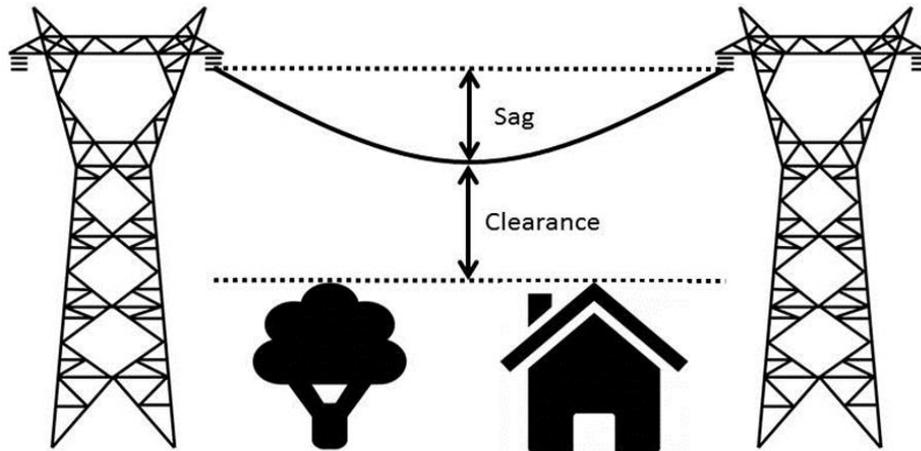
**Tableau 1-2.** Nombre de projets répertoriés par ENTSO-E utilisant le DLR, en fonction du niveau de tension associé [30].

Niveau de tension	Nombre de projets répertoriés par ENTISOE
110 kV	6
150 kV	2
220 kV	14
400 kV	14

### 1.3. Lien entre le RTLR et les observations météorologiques

Pour définir le courant maximal autorisé pour éviter les échauffements trop importants, plusieurs équations sont à utiliser. Deux premières sont mécaniques, une équation de chaînette et une équation de changement d'état, et lient la température de la ligne à ses déformations. De ces équations, il est possible de tirer la valeur de distance observée entre la ligne électrique et les objets pouvant être situés sous la ligne (*clearance*), en fonction de la température au cœur de la ligne (**Figure 1-5**). Cette distance devant rester supérieure à une valeur seuil, et considérant alors une flèche maximale (*sag*), une température maximale peut être définie. Par la suite, une équation de chaleur lie la température de la ligne, le courant passant au cœur de celle-ci et les paramètres météorologiques.

Considérant une valeur seuil de flèche maximale et un ensemble de paramètres météorologiques statique pour le SLR, ou dynamique avec le DLR, il est alors possible de définir une valeur de courant maximal. Dans cette section, nous présentons l'ensemble de ces équations, celles-ci ayant été utilisées tout le long de ce doctorat.



**Figure 1-5.** Pour une ligne électrique aérienne, schéma représentant la flèche (sag) et la distance entre la ligne et les objets en-dessous (clearance).

### 1.3.1. Equations mécaniques liant la flèche de la ligne et sa température

Dans l'optique de limiter les risques associés à la gestion des lignes électriques, un impératif de sécurité est associé à la flèche maximale de la ligne. Plusieurs problématiques peuvent être associées à cette déformation, comme des déformations permanentes, mais la principale motivation est de borner la distance minimale entre la ligne électrique et les objets pouvant être situés en-dessous pour des raisons de sécurité.

La flèche de la ligne est, dans le cas de deux extrémités de pylônes situés à la même altitude, peut être calculé à l'aide d'une approximation parabolique d'une équation de chaînette [7] :

$$\text{Sag} \approx \frac{m \cdot g \cdot L^2}{8 \cdot H} \quad (1-1)$$

où  $m$  (kg/m) représente la masse linéique de la ligne,  $g$  ( $\text{m/s}^2$ ) est la valeur de l'accélération de la pesanteur,  $L$  (m) est la distance séparant les deux pylônes et  $H$  (kg/m) est la tension mécanique axiale.

Considérant une différence d'altitude entre les deux pylônes, l'approximation suivante est généralement utilisée pour obtenir la valeur de la flèche :

$$\text{Sag} \approx \frac{m \cdot g \cdot L \cdot p}{8 \cdot H} \quad (1-2)$$

$$p = \sqrt{L^2 + h^2} \quad (1-3)$$

où le paramètre  $h$  est la différence d'altitude entre les deux pylônes (m).

Le paramètre  $H$  est lié à la température au cœur de la ligne, avec une équation d'équilibre entre l'état de la ligne et un état de référence 0 :

$$0 = A \cdot (T_{c0} - T_c) + B \cdot \left( \frac{1}{H^2} - \frac{1}{H_0^2} \right) - H - H_0 \quad (1-4)$$

où les paramètres  $A$  ( $\text{kg m s}^{-2} \text{K}^{-1}$ ) et  $B$  ( $\text{kg}^3 \text{ m}^3 \text{ s}^{-6}$ ) sont des paramètres dépendant des propriétés du conducteur comme le module de Young et la surface de section du câble, où  $T_c$  (K) représente la

température au cœur de la ligne et  $T_{c0}$  (K) est une température de référence, souvent une température de 20°C, une valeur de tension mécanique axiale  $H_0$ (kg/m) correspondant à cette température.

A partir de ces deux équations (1-1)-(1-4), il est alors possible de fixer une température maximale pour les câbles, en fonction de la flèche maximale autorisée. En pratique, une valeur de température de référence pour chaque câble est souvent utilisée, et nous avons utilisé cette approche dans notre travail, les équations mécaniques n'étant alors pas utilisées.

### 1.3.2. Equation de chaleur pour la définition de l'intensité maximale de courant admissible

Après les équations mécaniques, la définition du courant maximal passe par une équation de chaleur, qui lie la température évoquée ci-dessus au courant de la ligne et aux paramètres météorologiques. Cette équation est utilisée par les gestionnaire de réseau et peut être tirée de deux documents standards relatifs aux calculs d'ampacité, le standard CIGRE [26] et le standard IEEE [25], peu de variations entre les deux étant à signaler [39].

Le principe du DLR repose sur cette équation de chaleur, qui peut être écrite comme ci-dessous :

$$P_j + P_s + P_m + P_i - (P_c + P_r + P_w) = mC_p \frac{dT_c}{dt} \quad (1-5)$$

où les différents paramètres correspondent à des phénomènes physiques :

- $P_j$  représente l'effet Joule (W).
- $P_s$  représente l'échauffement solaire, lié à l'irradiation solaire (W).
- $P_m$  est l'échauffement magnétique (W).
- $P_i$  représente l'effet couronne (W).
- $P_r$  représente le refroidissement par radiation (W).
- $P_c$  représente le refroidissement par convection (W).
- $P_w$  représente le refroidissement par évaporation (W).
- Le terme  $mC_p \frac{dT_c}{dt}$  traduit la dynamique de l'échauffement du câble (W).

Plusieurs de ces termes peuvent être négligés. Pour le cas du calcul d'ampacité, les calculs étant faits en régime permanent, le terme  $mC_p \frac{dT_c}{dt}$  peut être fixé à 0 W. Ce terme peut avoir une importance dans d'autres contextes, par exemple pour des définitions de courants maximaux associés à des régimes transitoires comme c'est le cas lors surcharges temporaires durant moins de 20 minutes. Dans le cas de cette thèse, comme nous avons principalement travaillé sur des prévisions RTLR avec des horizons supérieurs à 6 heures et non sur des prévisions à très court terme, nous avons négligé ce terme.

Ensuite, certains termes de chaleur ne sont généralement pas considérés dans les standards IEEE et CIGRE :

- Le refroidissement par évaporation. Ce terme n'est généralement pas significatif devant les autres termes de refroidissement. Des calculs de température de ligne électrique tenant compte de l'évaporation et des précipitations sont présentés dans [40], [41].

- Le refroidissement magnétique est négligé, même si cette hypothèse doit être considérée avec précaution dans le cas de conducteurs à cœur ferreux. Dans ce deuxième cas, l'ampacité diminue de manière générale de 0% à 3% [39].
- L'effet corona [42], aussi appelé effet couronne, est un effet qui peut avoir lieu en cas de vents importants et de précipitations. Dans ces situations, le terme devient négligeable devant les termes de refroidissement par convection et par évaporation, il est alors négligé dans les équations.

La formule utilisée pour les calculs d'ampacité peut donc être simplifiée sous la forme suivante (1-6), définie dans les modèles IEEE et le modèles CIGRE :

$$P_j + P_s = P_c + P_r \quad (1-6)$$

Dans cette section, nous décrivons les 4 différents termes de chaleur présents dans l'équation (1-6).

### 1.3.2.1. L'effet Joule, $P_j$

Pour calculer l'effet Joule dans une ligne électrique dans un contexte de calcul d'ampacité, il est nécessaire de prendre en compte l'impact de la température de la ligne électrique sur la résistance de la ligne. On peut alors exprimer le terme de l'effet Joule ainsi (1-7) :

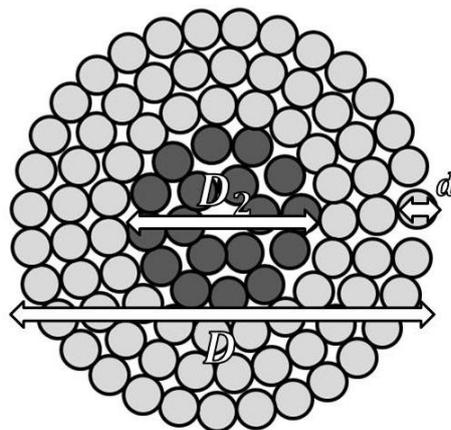
$$P_j = k_j \cdot I^2 \cdot R_{DC} [1 + \alpha \cdot (T_{av} - 20)] \quad (1-7)$$

où  $R_{DC}$  est la résistance DC par unité de longueur de la ligne à 20°C ( $\Omega/m$ ),  $\alpha$  est le coefficient de résistance par Kelvin ( $K^{-1}$ ),  $T_{av}$  est la température moyenne de la ligne (°C),  $I$  est le courant passant dans la ligne (A) et  $k_j$  est un paramètre permettant de prendre en compte l'effet de peau (U.A.). Pour ce dernier paramètre, il est recommandé d'utiliser une valeur de 1,0123 [26].

Pour  $T_{av}$ , il peut être souhaitable dans certaines approches d'en obtenir une valeur fine, de même qu'avec la température au cœur de la ligne qui peut être différente de celle à sa surface. Considérant la génération de chaleur entre les limites du noyau de la ligne et sa surface, et ce de manière homogène, une formule permet de donner la valeur du différentiel de température entre le cœur du câble et sa surface :

$$T_c - T_s = \frac{P_j}{2 \cdot \pi \cdot \lambda} \cdot \left[ \frac{1}{2} - \frac{D_2^2}{D^2 - D_2^2} \cdot \ln \left( \frac{D}{D_2} \right) \right] \quad (1-8)$$

où  $\lambda$  est la conductivité thermique dans la ligne (typiquement 2W/mK),  $D$  est le diamètre de la ligne (m),  $D_2$  est le diamètre du cœur de la ligne (m). On représente les deux diamètres sur une coupe transversale de ligne, sur la **Figure 1-6**.



**Figure 1-6.** Schéma de coupe transversale d'une ligne électrique.

Cependant, il est à remarquer que la différence entre la température au cœur de la ligne  $T_c$  et la température à sa surface  $T_s$  varie en général entre  $0,5^\circ\text{C}$  et  $7^\circ\text{C}$ . Dans ces conditions, il est possible de considérer ces trois températures comme égales, et nous avons repris cette hypothèse dans la suite de nos travaux (1-9) :

$$T_c \approx T_s \approx T_{av} \quad (1-9)$$

### 1.3.2.2. L'irradiation solaire, $P_s$

L'irradiation solaire peut être calculée assez simplement avec la formule suivante (1-10) :

$$P_s = \alpha_s \cdot S \cdot D \quad (1-10)$$

où  $S$  représente l'irradiation globale (W/m), et  $D$  le diamètre du conducteur (m),  $\alpha_s$  représente le coefficient d'absorption de la ligne (U.A.). Ce paramètre peut varier de 0,3, pour un câble ayant de l'aluminium brillant, à 0,95 pour un câble érodé dans un environnement industriel. Une valeur de 0,5 est considérée dans notre travail.

### 1.3.2.3. Le refroidissement par radiation, $P_r$

Ce terme de radiation correspond à la somme d'une perte de chaleur par rayonnement due à la température du câble et à un gain de chaleur dû à l'absorption de rayonnement par l'environnement. On l'écrit ainsi à l'aide de la loi de Stefan-Boltzmann (1-11) :

$$P_r = \pi \cdot D \cdot \varepsilon \cdot \sigma_B \cdot [(T_s + 273)^4 - (T_a + 273)^4] \quad (1-11)$$

où  $\sigma_B$  est la constante de Boltzmann ( $\text{m}^2 \text{kg s}^{-2} \text{K}^{-1}$ ),  $T_a$  est la température ambiante de l'air ( $^\circ\text{C}$ ) et  $T_s$  est la température de surface du câble ( $^\circ\text{C}$ ).

Le dernier paramètre,  $\varepsilon$  (U.A.), l'émissivité, est un paramètre dépendant comme  $\alpha_s$  de l'état de surface du conducteur et variant entre 0,2 et 1, une valeur de 0,5 étant utilisée par défaut dans notre travail. On signalera la formule proposée dans [43] pour le calcul de ce terme, en fonction du nombre d'années  $N_a$  où la ligne électrique a été utilisée :

$$\varepsilon = 0,23 + 0,7 \cdot \frac{N_a}{1,22 + N_a} \quad (1-12)$$

### 1.3.2.4. Le refroidissement par convection, $P_c$

Le refroidissement par convection correspond à l'échange thermique dû au mouvement d'air autour du câble, et peut être calculé avec la formule suivante (1-13) :

$$P_c = \pi \cdot \lambda_f \cdot \text{Nu} \cdot (T_s - T_a) \quad (1-13)$$

où  $\lambda_f$  (W/K) est la conductivité thermique de l'air et  $\text{Nu}$  est le Nusselt (U.A.). Le premier terme  $\lambda_f$  dépend directement de la température ambiante et de la température à la surface de la ligne (1-14) :

$$\lambda_f = 2,42 \cdot 10^{-2} + 7,2 \cdot 10^{-5} \cdot 0,5 \cdot (T_s + T_a) \quad (1-14)$$

Le Nusselt, lui est défini selon différentes formules fonction du régime (naturel, forcé ou turbulent) dans lequel on se trouve :

- Le premier régime correspond à un écoulement naturel de l'air autour de la ligne. Pour ce régime, le Nusselt  $\text{Nu}_n$  est calculé avec la formule suivante (1-15) :

$$Nu_n = A_2 \cdot (Gr \cdot Pr)^{m_2} \quad (1-15)$$

où Gr est le nombre de Grashof (U.A.) (1-16), et Pr est le nombre de Prandtl (U.A.) (1-17) :

$$Gr = \frac{D^3 \cdot (T_s - T_a) \cdot g}{(T_f + 273) \cdot v^2} \quad (1-16)$$

$$Pr = \frac{c \cdot \mu}{\lambda_f} \quad (1-17)$$

Avec c la chaleur spécifique de l'air à température constante (K/kg.K),  $\mu$  la viscosité dynamique de l'air (kg/m.s) et v la viscosité cinématique de l'air (m<sup>2</sup>/s). La relation entre le Grashof, le Prandtl et les valeurs de  $A_2$  et  $m_2$  sont présentées dans le **Tableau 1-3**.

**Tableau 1-3.** Relation entre Gr·Pr,  $A_2$  et  $m_2$

Gr·Pr		$A_2$	$m_2$
De	A		
10 <sup>2</sup>	10 <sup>4</sup>	0,850	0,188
10 <sup>4</sup>	10 <sup>6</sup>	0,480	0,250

- Le régime laminaire forcé est un régime où la vitesse du vent a une influence sur le refroidissement, en général pour des vitesses de vent supérieures à 0,5m/s. Le Nusselt est calculé avec la formule suivante, considérant un vent perpendiculaire à la ligne (1-18) :

$$Nu_{f,\delta=90^\circ} = B_1 \cdot (Re)^n \quad (1-18)$$

où Re est le nombre de Reynolds (U.A.) :

$$Re = \frac{V \cdot D}{\nu} \quad (1-19)$$

où V est le module de la vitesse du vent (m/s). Comme montré sur le **Tableau 1-4**, les paramètres  $B_1$  et n dépendent du Reynold et de l'état de rugosité de la ligne  $R_f$ , donné par la formule  $R_f = \frac{d}{[2 \cdot (D-2d)]}$ .

**Tableau 1-4.** Relation entre  $B_1$ , n, Re et  $R_f$

Surface	Re		$B_1$	n
	De	à		
Toutes surfaces	10 <sup>2</sup>	2,65	0,641	0,471
$R_f \leq 0,05$	$> 2,65 \cdot 10^3$	$5 \cdot 10^4$	0,178	0,633
$R_f > 0,05$	$> 2,65 \cdot 10^3$	$5 \cdot 10^4$	0,048	0,800

Par la suite, on doit considérer des vents non perpendiculaires à la ligne, ce qui peut avoir une influence importante, le fait de passer d'un vent perpendiculaire à un vent parallèle pouvant réduire l'effet du refroidissement par convection de 60%. En fonction de l'angle d'attaque  $\delta$ , la formule suivante donne la valeur du Nusselt (1-20) :

$$Nu_{f,\delta} = Nu_{f,\delta=90^\circ} \cdot [A_1 + B_2(\sin \delta)^{m_1}] \quad (1-20)$$

où les termes  $A_1$ ,  $B_2$  et  $m_1$  dépendent de  $\delta$  :

- Si  $0^\circ < \delta < 24^\circ$ , alors  $A_1=0,42$ ,  $B_2=0,68$  et  $m_1=1,08$
- Si  $24^\circ < \delta < 90^\circ$ , alors  $A_1=0,42$ ,  $B_2=0,58$  et  $m_1=0,90$

- Le régime turbulent. Ce régime n'est pas considéré en général, comme c'est expliqué dans [25], car les situations où des régimes turbulents sont observés sont rarement généralisables tout le long de lignes pouvant faire plusieurs dizaines de kilomètres de long.

Le calcul du Nusselt nécessite alors de savoir si on est dans le régime de l'écoulement naturel ou le régime laminaire forcé. Pour ce faire, les standards IEEE et CIGRE recommandent de calculer les deux valeurs de Nusselt associées aux deux régimes, et de fixer le Nusselt utilisé en pratique comme le maximum des deux valeurs (1-21) :

$$Nu = \max(Nu_n, Nu_{f,\delta}) \quad (1-21)$$

### 1.3.2.5. Conclusion – formule finale

Considérant une température maximale au cœur de la ligne définie, assimilée à la température de surface de la ligne, et obtenue de manière à avoir une flèche minimale, il devient possible avec l'équation (1-6) d'obtenir une valeur d'ampacité dans la ligne avec l'équation (1-22) :

$$I_{\max} = \sqrt{\frac{P_c + P_r - P_s}{k_j \cdot R_{DC} \cdot [1 + \alpha \cdot (T_{c,\max} - 20)]}} \quad (1-22)$$

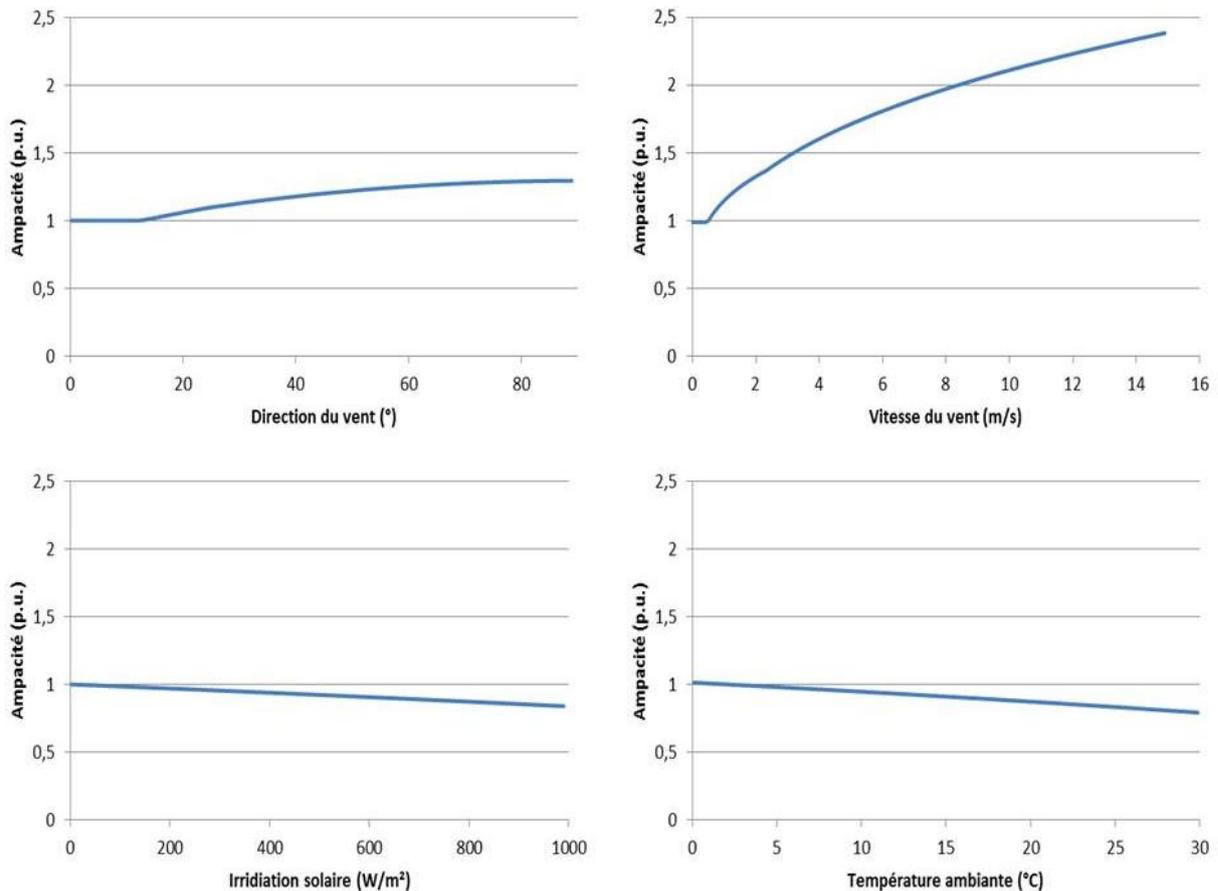
### 1.3.3. Sensibilité du DLR aux paramètres météorologiques

Pour visualiser les effets des paramètres météorologiques, on considère ici l'évolution de l'ampacité des lignes en fonction de l'évolution de chacun des 4 paramètres météorologiques considérés comme influents dans les termes de chaleur présentés dans la section 1.3 : la température ambiante, l'irradiation solaire, la vitesse du vent et la direction du vent.

Chaque paramètre étant évalué indépendamment des trois autres, des valeurs météorologiques contraignantes caractéristiques de l'hiver sont prises en compte pour les paramètres fixés, ces valeurs considérées étant utilisées dans [27] pour fixer des valeurs de SLR :

- une vitesse de vent de 0,5m/s,
- une irradiation solaire de 0W/m<sup>2</sup>,
- une direction du vent parallèle à la ligne,
- une température ambiante de 2°C.

Le modèle physique et les valeurs par défaut (absorptivité et émissivité de la ligne) utilisées sont celles décrites dans la partie 0. Les caractéristiques d'un câble Lynx 175 mm<sup>2</sup> sont considérées. L'évolution de l'ampacité, ici normalisée en fonction de la valeur du SLR associée aux valeurs présentées, est montrée sur la **Figure 1-7**.



**Figure 1-7.** Evolution de l'ampacité réelle d'une ligne électrique aérienne en fonction de différents paramètres météorologiques.

Sur ces graphiques, on constate que le principal paramètre ayant un impact sur le refroidissement des lignes est la vitesse du vent, une augmentation maximale de 140% étant observée pour les plages illustrées. De plus, on peut ajouter le fait que si la direction du vent était perpendiculaire à la ligne, une augmentation de 220% serait alors observée, à comparer aux variations de l'ordre de 20% observées lorsque ce sont la température ambiante et l'irradiation solaire qui évoluent.

En raison de ce lien entre le vent et l'ampacité, l'idée que le DLR aurait une utilité importante pour l'introduction d'énergie éolienne est régulièrement défendue, l'énergie ainsi produite étant alors fortement corrélée à l'ampacité des lignes situées à proximité. Cette corrélation est discutée plus tard dans la Section 1.4.2.

### 1.3.4. Considérations sur la section critique de la ligne

On considère une section de ligne comme un segment de lignes liant deux pylônes. Chaque segment peut avoir une valeur de rating associée, ne dépendant que des conditions météorologiques locales, et on définit la section critique de la ligne comme la section où la valeur minimale de rating est observée pour tout le long de la ligne.

En pratique, la valeur du DLR doit être fixée en accord avec la valeur de rating associé à cette section, et la recherche de cette section se fait à l'aide d'un ensemble de dispositifs DLR installés tout le long de la ligne.

Du point de vue de la mesure, il peut être problématique d'installer des centaines d'outils de mesure pour obtenir les valeurs de rating pour l'ensemble des sections. On peut alors installer des stations météorologiques équidistantes considérant une proportion de sections non considérées, ou alors faire une analyse sur les données associées aux différentes sections pour en tirer des localisations plus judicieuses permettant de réduire fortement le nombre de stations requises. Dans [44], il est ainsi montré qu'une telle sélection permettrait de manière générale de diviser le nombre de stations requises par un facteur allant de 2 à 5, par rapport à une installation de stations équidistantes, et cela tout en maintenant un même niveau de fiabilité.

Nous avons plus tôt évoqué l'intérêt du DLR, par exemple pour l'introduction d'énergies éoliennes, en raison de l'impact de la vitesse du vent sur sa valeur du RTL en un point donné. Cependant, la variabilité de la position de la section critique de la ligne peut être problématique pour des utilisateurs de DLR souhaitant utiliser de tels paramètres pour calculer les valeurs de rating, et on notera alors que, et même si cela reste rare, certains auteurs n'utilisent que la température ambiante pour définir les valeurs et des prévisions du DLR, considérant que seul ce paramètre est suffisamment stable tout le long d'une ligne pour pouvoir permettre d'obtenir un rating satisfaisant [45]–[47].

Dans notre travail, nous considérons régulièrement qu'une station météorologique étudiée est constamment localisée à la position de la section critique d'une ligne. Cette hypothèse, présente par exemple dans [48], facilite l'évaluation de certains modèles de prévision en permettant de travailler sur un grand nombre d'observations, des concaténations des résultats obtenus pour plusieurs stations étant alors possibles.

## 1.4. Bénéfices de l'utilisation du DLR

Comme on vient de le montrer dans la sous-section 1.3.3, le fait d'utiliser le DLR pourrait théoriquement permettre des augmentations importantes du courant admissible dans une ligne électrique. Ces améliorations offrent de nombreux avantages potentiels étayés dans la littérature, qui peuvent être succinctement résumés en trois points :

- Le coût du dispatching de la production de l'électricité est réduit.
- L'introduction d'énergies renouvelables est facilitée, en particulier la production éolienne.
- La fiabilité du réseau électrique est améliorée.

Nous proposons ici une reprise des principales recherches liées à ces 3 points ainsi que les résultats qui y sont mis en exergue.

### 1.4.1. Une réduction des coûts de l'électricité

#### 1.4.1.1. Impact sur la réduction des coûts de congestion

Le premier point à souligner par rapport à la levée de contraintes de réseau est la possibilité de réduire les coûts des congestions. Ces congestions sont en effet coûteuses, pouvant par exemple occasionner annuellement des pertes de l'ordre du milliard de dollars pour certains opérateurs de réseaux américains [49].

Plusieurs exemples dans la littérature donnent des évaluations des ordres de grandeurs des réductions potentielles de ces coûts permises par le DLR. Dans [50], le cas d'un réseau canadien à 3 nœuds est étudié, et il est montré que pour une semaine donnée, le coût de l'électricité pourrait théoriquement être abaissé de 7%, une centrale hydraulique étant moins limitée par des phénomènes de congestion dans sa production. Cette étude illustre le potentiel offert par le DLR, même si elle a néanmoins la faiblesse de considérer les prévisions DLR comme parfaites, ce qui réduit fortement la crédibilité du bénéfice potentiel avancé.

Ce point est dépassé dans [51], où les auteurs prennent en compte les prévisions probabilistes du DLR. Sur un réseau IEEE à 30 nœuds poussé à ses limites avec une augmentation des charges, ils évaluent l'impact de prévisions parfaites et quantiles du DLR sur les coûts de production, ainsi que la fréquence des situations où des accidents entraîneraient une impossibilité à continuer d'alimenter les charges de manière normale. Ils démontrent pour leur cas d'étude que le fait d'utiliser des prévisions quantiles à 1% ou 10% permet d'obtenir théoriquement entre un tiers et deux tiers des gains associés à des prévisions parfaites, tout en conservant une fiabilité acceptable sur le réseau. Pour ce réseau, les réductions des coûts totaux d'opérations permises par le DLR varient entre 0,3% et 1%, en fonction du niveau de probabilité utilisé pour définir les prévisions ponctuelles du DLR. Nous signalerons ici que dans le chapitre 5 où nous présentons des études similaires sur des études de coût avec un réseau IEEE à 24 nœuds, nous avons aussi trouvé des réductions des coûts d'opérations permises par le DLR variant entre 0,5% et 1,0%.

#### 1.4.1.2. Cas particulier des interconnexions électriques

Le DLR est régulièrement mis en avant comme un atout pour permettre d'améliorer les capacités d'échange entre des zones différentes, particulièrement dans un environnement de dérégulation du marché de l'électricité. Dans [52], seul cet aspect est d'ailleurs mis en avant comme bénéfique de l'implantation du DLR.

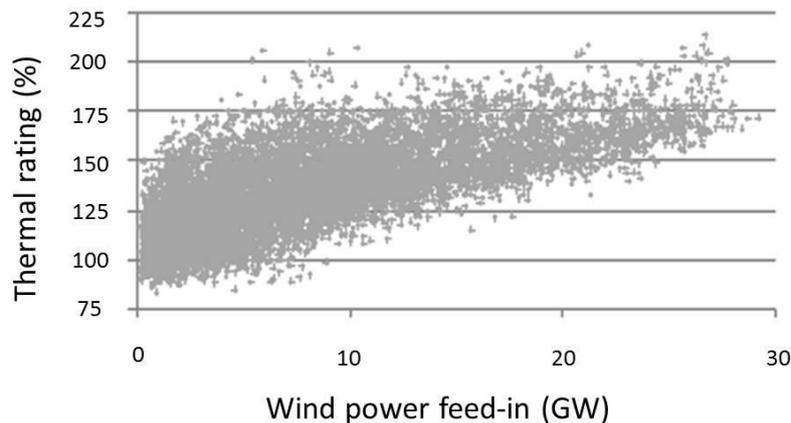
Relativement à ces interconnexions, dans [53], les auteurs proposent de définir des valeurs de capacités d'échange entre des marchés, considérant des simulations sur un réseau à 30 nœuds et des *optimal power flows*, ainsi que des valeurs d'ampacité modifiée avec le DLR. Dans le cas d'étude considéré, les auteurs cherchent à définir des fonctions linéaires liant les paramètres météorologiques et les valeurs de capacité d'échange, de manière à fournir un outil aisément utilisable.

Les avantages des bénéfices financiers que nous avons évoqués sont alors transposables à la gestion des connexions entre les marchés de l'électricité connectés. Pour le cas spécifique d'une ligne connectant la Finlande et la Suède, sur un total de 500 heures où des congestions étaient observés, les auteurs de [45] étaient arrivés à la conclusion que le DLR pouvait, avec les hypothèses faites par les auteurs, permettre une baisse moyenne du coût de l'électricité en Finlande d'à peu près 4,7 €/MWh, soit 10% du coût moyen. Ce chiffre est important, même si les hypothèses utilisées sont simplificatrices, les auteurs posant par exemple que lorsque le DLR est utilisé, la différence des coûts entre les deux marchés est arbitrairement divisée par deux.

## 1.4.2. Implantation facilitée pour les énergies éoliennes

### 1.4.2.1. Corrélations entre DLR et production éolienne

Une certaine complémentarité existe entre les énergies éoliennes et le DLR. En effet, la valeur de la chaleur dissipée par convection dans une ligne connectée à une ferme éolienne est fortement corrélée à la production électrique de cette ferme. Des ordres de grandeur sont fournis dans [54], où une corrélation variant entre 0,47 et 0,66 est trouvée entre les observations du RTLRL d'une ligne et les valeurs de la production d'une ferme éolienne située à une distance de 100 km, et dans [55], où une valeur de 0,79 est mise en avant pour le cas d'une ferme éolienne plus proche. On reprend sur la **Figure 1-8** un exemple de mesures RTLRL mises en relation avec des productions éoliennes, présenté dans [55].



**Figure 1-8.** Valeurs d'ampacité réelle d'une ligne électrique aérienne fonction du niveau de production électrique d'une ferme éolienne située à proximité [55]

Considérant ces corrélations avec un set de scénarios préétabli, l'étude [54] évalue la fréquence des situations où des lignes peuvent être congestionnées sur un réseau incluant des énergies éoliennes, et la présence ou non de DLR. La réduction observée pour une des lignes du réseau est significative, la fréquence des situations où cette ligne est congestionnée passant de 28% à 2,9% avec le DLR. De plus, une évaluation des coûts liés aux congestions est faite pour une saison hivernale, et il est montré, pour ce cas d'étude, que ces coûts peuvent être réduits de 53%.

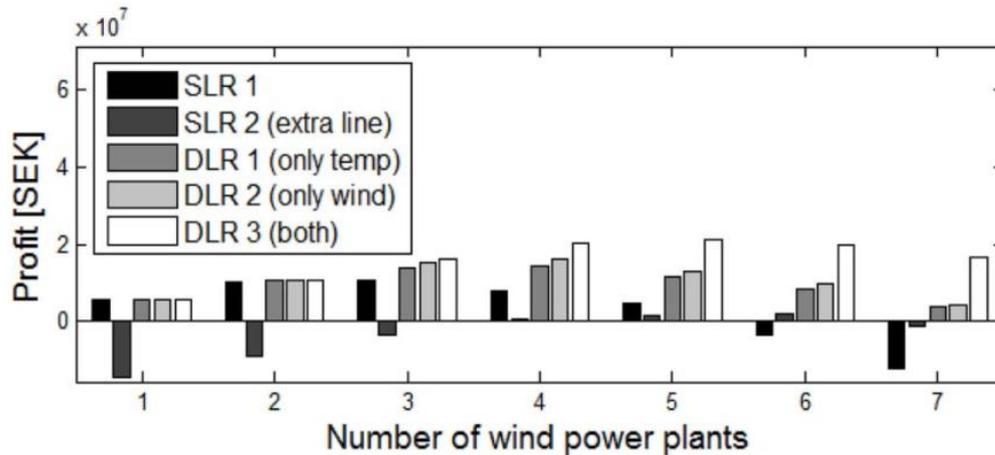
Dans [56], les auteurs évaluent que en raison de ces corrélations, le DLR permettrait de manière générale d'implanter entre 20% et 50% d'énergies éoliennes en plus sur les réseaux électriques par rapport à si le SLR était utilisé.

### 1.4.2.2. Modification des stratégies d'investissement sur le réseau

Ces modifications peuvent permettre aux gestionnaires de réseau de modifier les stratégies d'investissement associées à l'implantation des centrales éoliennes [57], [58].

Dans [58], les auteurs comparent le prix du renforcement au prix du DLR dans un contexte de raccordement d'une ferme éolienne, en calculant les profits théoriques totaux sur une période de 20 ans (**Figure 1-9**). Ces profits sont calculés en tenant compte des congestions, des bénéfices associés à la vente de l'énergie éolienne et du coût de construction d'une nouvelle ligne. Il faut souligner que le coût du DLR n'est pas pris en compte, ce coût n'étant pas nécessairement négligeable par rapport au coût du renforcement sur un réseau de distribution, comme on l'a évoqué dans la section 1.2.4. On constate

cependant qu'avec un coût théorique nul pour le DLR, les bénéfices attendus pour l'exploitation d'une ferme éolienne grâce à l'installation du DLR pourrait être jusqu'à doublés par rapport à si des méthodes de renforcement traditionnelles étaient utilisées, ce qui justifie l'intérêt du DLR comme alternative au renforcement.



**Figure 1-9.** Profits financiers totaux pour une ferme éolienne, en fonction du nombre d'éoliennes installées, et de la stratégie associée à la ligne connectant la ferme au réseau : pas de modification de la ligne (SLR1), utilisation du renforcement (SLR2) et utilisation du DLR, en ne considérant que l'influence de la température ambiante (DLR1), du vent (DLR2) ou des deux paramètres simultanément (DLR3).

Relativement à la stratégie d'investissement sur les réseaux électriques, on signalera aussi [59]. Dans cet article, les auteurs s'intéressent à différentes stratégies permettant de réduire les coûts sur un réseau pour des périodes de plusieurs années, en considérant une introduction croissante de fermes éoliennes par plusieurs étapes. Le DLR est utilisé en complément de l'implantation d'autres alternatives, ici des renforcements de transformateurs et de lignes, l'introduction d'un compensateur statique d'énergie réactive et l'ajout de transformateurs déphaseurs. Cette étude ne permet cependant pas de connaître la part précise des bénéfices dus au DLR par rapport à d'autres modifications.

#### 1.4.2.3. Utilisation de prévisions DLR et éoliennes

En plus du cadre de l'utilisation en temps réel, le DLR peut être pris en compte dans des stratégies de prévision de la production éolienne, à l'aide de méthodologies d'optimisation stochastiques. Cela est proposé dans [60], où les auteurs évaluent l'apport du DLR avec l'étude d'un réseau IEEE et de deux distributions de probabilité, associées aux prévisions pour une ferme éolienne et pour le DLR situé sur une ligne. Pour un instant donné, il est montré que le coût attendu pour fournir les consommateurs peut baisser d'à peu près 20%.

Une étude similaire est faite dans [61], où les auteurs procèdent ainsi en considérant un réseau IEEE à 14 nœuds, et 3 courbes de densité de probabilité associées aux productions de deux fermes éoliennes et de la valeur du DLR pour l'ensemble des lignes. Une caractéristique notable de cette étude, que l'on retrouve par la suite dans [62], [63], est l'introduction de coûts associés aux dépassements des capacités des lignes, là où de tels dépassements sont traditionnellement interdits lors de la mise en place des actions de correction sur le réseau.

### 1.4.3. Amélioration de la fiabilité du réseau

#### 1.4.3.1. Optimal Power Flow prenant en compte le DLR et la fiabilité du réseau

En plus des différents bénéfices économiques, il a été montré plusieurs fois que le DLR pouvait aider à améliorer la fiabilité du réseau électrique, en fournissant une plus grande flexibilité en cas de défaillance. Cela peut être montré avec l'évaluation de différents indices, comme le Loss Of Load Expectation (LOLE), qui évalue le nombre d'heures annuel théorique où la production ne pourrait pas satisfaire la demande. Une évaluation de cet indice pour différents réseaux IEEE est calculé dans [64], le DLR étant inclus dans le réseau. Il y est montré que le DLR pourrait théoriquement permettre une réduction du LOLE de l'ordre de 33% par rapport à sa valeur initiale.

Un résultat similaire est montré dans [65]. Les auteurs comparent deux approches, l'une avec une gestion de la demande active, et l'autre avec la même gestion de la demande active et le DLR en complément. Ici, l'indice de l'Expected Energy Not Supplied (EENS) est évalué et il est montré pour ce cas d'étude que l'ajout du DLR permet d'abaisser l'indice de 475 MWh/jour à 183 MWh/jour, soit une réduction de 61,5%.

Enfin, un intérêt est aussi montré dans [51] pour l'utilisation non pas de valeurs instantanées de DLR, mais de prévisions à bas quantile. Une réduction importante du nombre de situations où le critère N-1 n'est pas respecté sur un réseau est en effet démontrée, à partir du moment où les valeurs du DLR sont fixées à partir de prévisions à bas quantile, le tout en permettant une amélioration significative des performances économiques par rapport à l'utilisation du SLR.

#### 1.4.3.2. Diminution des risques d'échauffement de ligne

Il est aussi à noter que bien que le principal avantage du DLR soit le fait que l'ampacité d'une ligne peut être augmentée la majorité du temps, le fait que le DLR puisse parfois réduire l'ampacité d'une ligne par rapport au SLR peut aussi être considéré comme un atout pour la gestion du réseau. Cela peut être particulièrement important pour des lignes où le SLR n'a pas été défini de manière à être statistiquement viable, c'est-à-dire comme étant supérieur au RLTR seulement 1% du temps.

De tels exemples se trouvent dans [55], où cette fréquence est de 5%, ou dans [24], où celle-ci atteint 40% en hiver.

#### 1.4.3.3. Possibilité de prendre en compte l'inertie de la température de la ligne

Nous avons évoqué précédemment les équations liant la température de la ligne au courant, en régime permanent. Il est cependant possible de considérer le régime transitoire, c'est-à-dire l'inertie de la température de la ligne, pour réaliser certaines opérations considérant que dans le délai associé à celles-ci, la température de la ligne ne peut dépasser une valeur critique.

Le procédé associé à ce type d'opérations est appelé coordination électrothermique et est présenté dans [66], [67]. Il permet dans des situations d'urgence d'offrir des marges de manœuvre pour améliorer la fiabilité ou les coûts des opérations du réseau. Ainsi, il est possible en cas de défaillance de ne pas avoir à utiliser d'appels de réserve si la défaillance peut être corrigée en quelques dizaines de minutes, ou alors de faire appel à des générateurs longs à activer mais moins coûteux que ceux qui auraient été initialement utilisés.

### 1.4.4. Une technologie prometteuse nécessitant des prévisions

Dans un contexte d'utilisation du DLR, il est souvent préférable qu'une valeur de DLR soit valide pour une certaine durée. D'après [68], cette durée peut varier entre 1 heure et 24 heures. Pour des durées inférieures à 1 heure, ces prévisions sont alors souvent assimilables au DLR instantané. Cela implique un premier point sur l'importance des prévisions pour le DLR : contrairement aux énergies renouvelables où les observations en temps réel correspondent à des mesures physiques, les valeurs de DLR utilisées en pratique peuvent correspondre, elles, à des valeurs de prévisions à très court-terme.

A cela, on peut ajouter que lorsque l'on observe les différents avantages présentés dans les paragraphes précédents, on peut constater que plusieurs reposent non seulement sur des processus impliquant des décisions en temps réel, mais aussi sur des décisions prises en amont.

Cela est par exemple visible pour les échanges d'électricité entre des marchés, où les quantités d'énergies échangées sont définies au moins plusieurs heures avant la concrétisation de ces échanges. Les contraintes du réseau doivent alors être connues à l'avance.

Pour ces raisons, il est nécessaire pour les opérateurs souhaitant utiliser le DLR et en exploiter pleinement les potentiels avantages de disposer de prévisions, de manière similaire à ce qui est fait avec les énergies renouvelables aussi dépendantes de paramètres météorologiques. Au vu de ces besoins, des méthodologies de prévision sont depuis récemment investiguées dans la littérature, et on présentera les différents travaux qui ont été faits sur ce sujet dans la section suivante.

## 1.5. Etat de l'art des méthodes de prévision du DLR

### 1.5.1. Généralités sur les prévisions DLR

#### 1.5.1.1. De la nature d'une prévision

Une prévision est une estimation future d'une grandeur donnée. Pour en définir les particularités, on peut tout d'abord considérer une prévision ponctuelle  $\hat{Y}_{t+h|t}$ , faite à un instant  $t$  pour un horizon  $h$ , et qui correspond à une seule valeur fournie pour l'estimation de la grandeur future, en fonction de paramètres d'entrées  $X_t$  connus à l'instant où la prévision est faite.

La relation entre  $X_t$  et  $\hat{Y}_{t+h|t}$  est fourni par un modèle, à l'architecture définie par l'opérateur et aux paramètres, soit définis en accord avec les connaissances des règles associées aux mécanismes étudiés (prévision déterministe), soit avec un apprentissage automatique (*machine learning* en anglais) à partir d'un échantillon d'apprentissage :

$$\hat{Y}_{t+h|t} = f(X_t) \quad (1-23)$$

Dans le deuxième cas, les modèles de prévision sont alors entraînés de manière à réduire les erreurs entre les prévisions  $\hat{Y}_{t+h|t}$  et les observations  $Y_{t+h}$  faites pour les  $N$  points d'un échantillon d'entraînement :

$$\sum_{k=1}^N L(\hat{Y}_{t+h|t_k}, Y_{t+h}) \quad (1-24)$$

où  $L$  est la fonction de perte (*Loss function* en anglais), qui permet d'évaluer la valeur d'une erreur associée à un couple d'observation et de prévision. L'une des fonctions de perte les plus populaires est la fonction de perte quadratique (MSE) :

$$L_{\text{MSE}}(\hat{Y}_{t+h|t}, Y_{t+h}) = (Y_{t+h} - \hat{Y}_{t+h|t})^2 \quad (1-25)$$

La définition de cette en fonction de perte est un point important, dans le sens où il permet une recherche plus ou moins aisée des paramètres du modèle  $f$ , ou qu'il peut permettre d'obtenir des prévisions plus adaptées à un problème donné. Par exemple, on peut juger qu'une prévision médiane obtenue avec la réduction de l'erreur absolue peut avoir une plus grande valeur qu'une prévision de la moyenne obtenue avec la réduction de la fonction de perte quadratique.

Ce deuxième point est important pour le cas du DLR. En effet, en plus d'objectifs associés au fait que les prévisions DLR doivent être proches des observations futures, celles-ci doivent respecter des critères de fiabilité contraignants [69]. En effet, le fait de sous-évaluer une prévision future, et donc d'avoir un manque à gagner relativement faible en raison d'une sous-utilisation de la ligne électrique, aura des conséquences modestes par rapport au fait d'au contraire surévaluer ces prévisions, des coûts associés à des redispatching ou à des augmentations importantes des risques sur le réseau pouvant découler de telles erreurs.

### 1.5.1.2. Obtention de prévisions DLR quantiles

Il faut souligner la différence entre le RTL et le DLR du point de vue de la prévision. La prévision du RTL correspond à la prévision d'une grandeur future, le courant admissible pour une ligne donnée. C'est une information sur l'état futur d'une variable. A partir de cette information, le gestionnaire de réseau prend une décision sur la valeur d'ampacité qui sera prise en compte dans les prises de décision, et cette valeur correspond à la prévision du DLR.

Pour définir la prévision du DLR, on remarque que beaucoup de gestionnaires de réseau utilisent des règles générales pour définir la prévision du DLR à partir de la prévision du RTL en considérant comme critère de sélection des niveaux de probabilité fixes de dépassement des prévisions par les futures observations [48], [51], [70]–[76].

Des prévisions ponctuelles quantiles sont alors intéressantes pour fournir des prévisions DLR, ce type de prévision étant déjà utilisé pour fournir des prévisions pour les énergies renouvelables de manière à par exemple optimiser des bénéfices économiques dans des contextes où les coûts de surévaluation et de sous-évaluation sont différents [77]. Celles-ci reviennent à fournir des prévisions  $\hat{Y}_{t+h|t}^\tau$  ayant une probabilité  $\tau$  d'être supérieure aux observations  $Y_{t+h}$ :

$$P(\hat{Y}_{t+h|t}^\tau > Y_{t+h}) = \tau \quad (1-26)$$

Il est à faire remarquer que dès lors qu'une prévision RTL  $\hat{Y}_{t+h|t,i}^\tau$  est fournie pour chaque station DLR  $i$  parmi  $n$  stations situées sur la même ligne, avec  $i=1, \dots, n$ , le problème de la définition d'une prévisions DLR à partir d'un quantile  $\tau$  doit être posé différemment, de telle manière à considérer la sélection de la section critique de la ligne parmi les  $n$  stations (1-27) :

$$P(\min_{i \in [1,n]} (\hat{Y}_{t+h|t,i}^\tau) > \min_{j \in [1,n]} (Y_{t+h,j})) = \tau \quad (1-27)$$

A quelques exceptions près [72], on ne considère généralement des prévisions que pour une seule station météo en la considérant comme toujours localisée sur la position de la section critique de la ligne.

Pour une seule station, de manière générale, ces prévisions quantiles peuvent être obtenues de deux manières différentes. Une première est l'utilisation de méthodes de régression, avec une en fonction de perte M-quantile étant minimisée. La plus utilisée est la fonction de perte Pinball  $L_{\text{Pinball}}^{\tau}$  (1-28) :

$$L_{\text{Pinball}}^{\tau}(\hat{Y}_{t+h|t}, Y_{t+h}) = \begin{cases} (\hat{Y}_{t+h|t} - Y_{t+h}) \cdot (1 - \tau) & \text{if } Y_{t+h} \leq \hat{Y}_{t+h|t} \\ (Y_{t+h} - \hat{Y}_{t+h|t}) \cdot \tau & \text{if } Y_{t+h} > \hat{Y}_{t+h|t} \end{cases} \quad (1-28)$$

L'utilisation de ce type de régression pour des quantiles allant de 0 à 1 permet d'obtenir directement des prévisions probabilistes, le minimum de la fonction de perte étant obtenu lorsque le ratio d'observations situées sous la prévision par rapport au nombre d'observations considérées est égal à  $\tau$ , ce qui se voit aisément en posant la dérivée de la fonction de perte.

Bien que rarement, un autre type de en fonction de perte est aussi parfois utilisé, la fonction de perte expectile  $L_{\text{Expectile}}^{\tau}$  [78], qui est équivalente à une fonction de perte MSE là où la fonction de perte Pinball correspondrait à une erreur absolue (1-29) :

$$L_{\text{Expectile}}^{\tau}(\hat{Y}_{t+h|t}, Y_{t+h}) = \begin{cases} (\hat{Y}_{t+h|t} - Y_{t+h})^2 \cdot (1 - \tau) & \text{if } Y_{t+h} \leq \hat{Y}_{t+h|t} \\ (Y_{t+h} - \hat{Y}_{t+h|t})^2 \cdot \tau & \text{if } Y_{t+h} > \hat{Y}_{t+h|t} \end{cases} \quad (1-29)$$

Même si la relation est moins évidente que pour des prévisions quantiles, il est possible à partir des expectiles de générer une fonction de probabilité cumulée associée à une prévision probabiliste [79], et donc par la suite d'obtenir des prévisions quantiles.

La deuxième méthode est l'utilisation de prévisions probabilistes. Ce type de prévisions fournit l'information sur l'ensemble des valeurs potentielles futures de la grandeur étudiée, ainsi que les probabilités associées à ces différentes possibilités. Là où une prévision quantile n'est qu'une valeur possible d'une variable aléatoire avec un niveau de probabilité donné d'être surestimée, une prévision probabiliste fournit simultanément toutes les valeurs possibles de la variable avec ces mêmes niveaux de probabilité.

De manière générale, l'ensemble des méthodes de prévision du RTL, en particulier à court terme (6 heures – 48 heures), peuvent être associées à ces deux approches.

## 1.5.2. Modèles de prévisions du DLR

### 1.5.2.1. Modèles de prévision du DLR – premiers modèles

A la suite de premières réflexions posées sur la prévision du DLR par le créateur de la technologie dans [28], le premier modèle de prévision probabiliste du DLR est défini dans [75], où les auteurs proposent un modèle fournissant des prévisions pour des horizons variant de 1 heure à 24 heures. Pour cela, des prévisions séparées des différents paramètres utilisés pour le calcul du DLR sont considérées, ici la température ambiante et le nombre de Nusselt. L'utilisation de ce dernier paramètre, liant la vitesse et la direction du vent, permet d'obtenir de meilleures prévisions d'après les auteurs qu'avec l'utilisation de la direction et de la vitesse du vent. A noter que quelques années plus tard, les auteurs développent un modèle similaire dans [47] où seule la température ambiante est prise en compte. Cette considération permet de travailler sans avoir à considérer la recherche de la section critique de la ligne, ce qui permet alors de réduire significativement les temps de calcul.

Les prévisions des deux composantes considérées sont calculées à partir d'une composante déterministe  $P_{t+h}$  et d'une composante stochastique  $Z_{t+h|t}$ .

$$\hat{Y}_{t+h|t} = P_{t+h} + Z_{t+h|t} \quad (1-30)$$

La première composante déterministe est obtenue à l'aide d'une décomposition par série de Fourier faite sur un ensemble d'apprentissage. Les composantes stochastiques sont obtenues avec des modèles autorégressifs pour la température ambiante et la direction du vent, et des modèles vecteurs autorégressifs pour la vitesse du vent et le nombre de Nusselt, la température ambiante étant ajoutée aux variables utilisées. Par la suite, considérant les erreurs de prévisions pour les composantes stochastiques, les auteurs définissent des variances associées aux prévisions des variables, des méthodes différentes étant utilisées dans [47] et [75]. Dans [75], les variances sont obtenues comme les sommes des variances associées aux bruits blancs des données d'entrées des modèles, et dans [47] la variance est obtenue seulement pour la température ambiante, comme dépendant de la variance obtenue pour une prévision faite en  $t-1$  pour l'instant  $t$  et de la variation entre l'observation de la température à  $t$  et la prévision moyenne pour  $t+1$ . A partir de ces variances, une variance est définie pour la prévision DLR,  $\widehat{V}_{a_{t+h|t}}$ , et considérant que la forme de la densité associée à la prévision DLR est une gaussienne, les auteurs posent alors de première prévisions quantiles du DLR, en particulier une prévision à quantile 2,5% (1-31) :

$$\hat{Y}_{t+h|t}^{2,5\%} = \hat{Y}_{t+h|t} - 1,96 \cdot \sqrt{\widehat{V}_{a_{t+h|t}}} \quad (1-31)$$

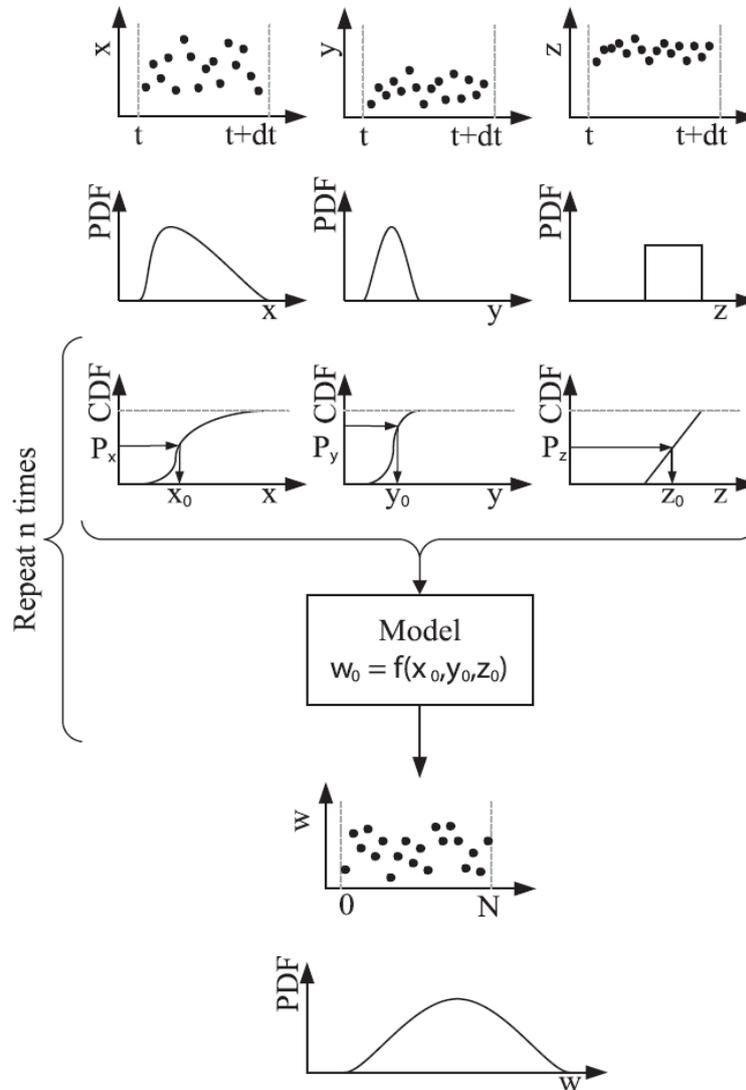
Il est à noter qu'un travail similaire a été fait récemment dans [80], [81] pour l'obtention d'une composante déterministe permettant de stationnariser les données. Pour des modèles de prévision DLR à très court terme, les auteurs ont aussi proposé de fournir des prévisions probabilistes pour différents paramètres météorologiques. Les valeurs moyennes de ces prévisions étaient obtenues à l'aide de modèles vecteur autorégressif prenant en compte des observations météorologiques pour un ensemble de stations météorologiques localisées le long d'une ligne, et les données d'entrée étaient dans cette optique stationnarisées à l'aide de séries de Fourier.

On citera ensuite l'article [43], dans lequel les auteurs définissent un système expert, soit un ensemble de règle permettant à partir de données d'entrée de définir des valeurs de DLR futures, en cas de surcharges. Il est intéressant de noter que sur la suite de leurs approches, dans [82], les auteurs proposent d'utiliser des réseaux de neurones pour générer les entrées de leurs premiers modèles, en terme de valeurs horaires d'irradiation solaire, et constituent alors le premier cas d'utilisation de réseaux de neurones pour la problématique du DLR.

On citera enfin [83], où des régressions linéaires quantiles [84] sont utilisées avec comme cas d'étude des données de réanalyse.

### 1.5.2.2. Prévisions à base de simulations de Monte Carlo

Pour une grande partie des études dans la littérature, nous avons constaté une méthodologie récurrente pour fournir des prévisions associées au DLR. Celle-ci est basée sur la génération de prévisions de courbes de densité de probabilité pour les 4 paramètres météorologiques considérés pour les calculs du RTLRL, obtenus avec des estimations paramétriques (i.e. les lois de densité associées aux prévision ont des formes de loi données), puis par une agrégation faite la plupart du temps avec une simulation de Monte Carlo et le modèle physique que l'on a présenté dans la section 1.3 (**Figure 1-10**).



**Figure 1-10.** Illustration du mécanisme de prévisions agrégées pour le DLR avec des prévisions probabilistes pour les différents paramètres météorologiques, et une simulation de Monte Carlo [85].

Il apparaît que chacun de ces paramètres est généralement modélisé soit avec une valeur ponctuelle, soit avec un type de densité de probabilité donné, dont on tire des exemples de la littérature :

- La vitesse du vent  $W_s$  est généralement modélisée avec une loi de distribution de Weibull (1-32) [73], [86], [87] :

$$\text{Weib}(W_s|\alpha, \beta) = \frac{\beta}{\alpha^\beta} W_s^{\beta-1} e^{-\left(\frac{W_s}{\alpha}\right)^\beta} \quad (1-32)$$

On note cependant que certaines approches utilisent des lois normales [88] ou des lois Beta [89].

- Dans toutes les études où des prévisions probabilistes de ce paramètres sont considérées, la direction du vent est modélisée avec une loi de distribution de Von Mises (1-33) [73], [86]–[88], adaptée à une variable évoluant dans un intervalle  $[0, 2\pi]$  :

$$\text{VM}(\varphi|\mu, k) = \frac{1}{[2\pi * I_0(k)]} e^{k * \cos(\varphi - \mu_\varphi)} \quad (1-33)$$

où  $0 \leq k \leq \infty$ ,  $0 \leq \mu_\varphi \leq 2\pi$ ,  $0 \leq \varphi \leq 2\pi$  et  $I_0$  est la fonction de Bessel d'ordre 0 :

$$I_0(k) = \sum_{p=0}^{\infty} \frac{1}{(p!)^2} \left(\frac{k}{2}\right)^{2p} \quad (1-34)$$

- La température  $T_a$  est modélisée à l'aide d'une loi normale [73], [86], [87] :

$$f(T_a|\mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{T_a-\mu}{\sigma}\right)^2} \quad (1-35)$$

Ce type de prévision est dans un premier temps utilisé pour évaluer non pas le DLR futur, mais les risques associés à l'utilisation d'une valeur de DLR donnée. L'objectif est de savoir, connaissant le courant passant dans une ligne, quelle est la probabilité que la température au cœur de la ligne atteigne des valeurs excessives.

Une méthodologie allant dans ce sens est présentée dans [86], plus tard reprise dans [88] et dans [87]. L'horizon des prévisions est d'une heure, et les auteurs cherchent à évaluer la densité de probabilité de la température future au cœur de la ligne, et non pas du DLR, ce qui implique des informations sur le courant au sein de la ligne. Cela est fait en estimant des densités de probabilité pour 3 paramètres météorologiques ; la vitesse du vent, sa direction et la température ambiante. L'irradiation solaire est considérée comme une prévision déterministe ponctuelle. Les paramètres des densités de probabilité sont obtenus avec des calculs de vraisemblance maximale, ou avec des inférences bayésiennes, et ce à partir des observations récentes des variables prédites.

Quelques années plus tard, ce type de méthodologie est reprise, cette fois pour des prévisions du DLR en J-1. L'une des principales différences est alors l'utilisation de prévisions météorologiques. Un premier modèle est proposé dans [89], où les auteurs utilisent des prévisions ponctuelles fournies par la National Oceanic and Atmospheric Administration (NOAA). Des densités de probabilité sont générées pour les paramètres liés au vent et à la température ambiante en considérant l'historique des erreurs de prévision. Dans une approche simplificatrice, les auteurs considèrent que les densités de probabilité associées aux prévisions météorologiques sont homoscédastiques, et que les paramètres relatifs à la variance peuvent être estimés à partir des historiques des erreurs de prévision sur des périodes de quelques jours.

Dans [73], il est aussi proposé de travailler à partir de densités de probabilité des prévisions météorologiques futures et de fournir le même résultat que [89]. Cependant, les densités des paramètres d'entrée ne sont plus générées à partir de prévisions météo ponctuelles et d'historiques d'erreurs, mais à partir de prévisions météorologiques ensemblistes. Ces prévisions sont fournies ici par la NOAA, et correspondent à un ensemble de prévisions calculées avec le même modèle physique et avec des conditions initiales légèrement modifiées de manière aléatoire pour chaque prévision. Les auteurs considèrent alors les différentes prévisions comme équiprobables, et de là en tire les caractéristiques des densités de probabilité associées.

Enfin, on citera [72]. Ici, les auteurs utilisent encore des prévisions de densités de probabilité pour les variables météorologiques d'intérêt, prévisions fournies à partir de prévisions météorologiques ponctuelles et d'un filtre de Kalman étendu entraîné avec un réseau de neurone. Ici, les auteurs ne considèrent plus une simulation de Monte Carlo, mais obtiennent directement les paramètres de la

densité de prévision du DLR à l'aide de série de Taylor considérant une décorrélation parfaite entre les variables (1-36)-(1-37) :

$$E(\hat{Y}_{t+h|t}) = I_{\max}(E(\hat{T}_{t+h|t}), E(\hat{U}_{t+h|t}), E(\hat{V}_{t+h|t})) \quad (1-36)$$

$$\sigma(\hat{Y}_{t+h|t})^2 = \left( \frac{\delta I_{\max}(\cdot)}{\delta \hat{T}_{t+h|t}} \Big|_{E(\hat{T}_{t+h|t})} \right)^2 \text{Var}(\hat{T}_{t+h|t}) + \left( \frac{\delta I_{\max}(\cdot)}{\delta \hat{U}_{t+h|t}} \Big|_{E(\hat{U}_{t+h|t})} \right)^2 \text{Var}(\hat{U}_{t+h|t}) + \left( \frac{\delta I_{\max}(\cdot)}{\delta \hat{V}_{t+h|t}} \Big|_{E(\hat{V}_{t+h|t})} \right)^2 \text{Var}(\hat{V}_{t+h|t}) \quad (1-37)$$

Le fait de passer par des prévisions météorologiques séparées et ensuite recombinaison pour fournir des prévisions DLR a deux grands avantages. Le premier est que si les prévisions sont fiables, et que l'on est en mesure d'avoir une bonne modélisation des corrélations des erreurs de prévision, il est possible d'obtenir des prévisions DLR à très bas quantile en utilisant des prévisions à quantiles supérieurs pour les différentes prévisions. Or, il peut être plus aisé d'obtenir de bonnes performances sur ce type de quantile pour des prévisions de paramètres météorologiques, que sur des quantiles inférieurs pour une prévision directe.

Le deuxième point intéressant est la généralisation du modèle de prévision à des cas d'utilisation du DLR différents. On a évoqué dans le chapitre précédent des articles où des méthodes de calcul du DLR différentes étaient utilisées, par exemple [58], où le DLR est calculé en considérant des combinaisons de paramètres météorologiques variables (soit seulement la vitesse du vent, soit seulement la température globale, soit les deux paramètres).

Même dans un contexte d'utilisation du DLR avec les 4 paramètres météorologiques, il est à envisager qu'un des appareils de mesure du dispositif DLR soit inutilisable, et que les opérateurs utilisant le DLR souhaitent alors utiliser un modèle de prévision prenant en considération un nombre de paramètres météorologiques réduit, ce que les prévisions agrégées permettent de faire.

Il faut cependant signaler plusieurs points relatifs à ces approches. On a vu que régulièrement, l'irradiation solaire n'était pas considérée pour les prévisions des paramètres utilisés, ce qui amenait les auteurs à ne considérer que trois paramètres : la température, la vitesse du vent et la direction du vent.

Ensuite, l'utilisation séparée de ces deux derniers paramètres associés au vent est problématique, en opposition à l'utilisation du nombre de Nusselt, qui représente la valeur du refroidissement par convection et qui est la résultante de la réunion de ces deux paramètres dans l'équation de chaleur.

Tout d'abord, il est montré dans [75] que la prévision du Nusselt seul peut être plus aisée et fournir de meilleurs résultats que la concaténation des deux prévisions de la direction et de la vitesse du vent. Surtout, il est à garder à l'esprit que la grande majorité des appareils de mesure associés au DLR ne mesurent que l'effet du vent sur la température du câble, donc le Nusselt, et pas directement les paramètres du vent. On a évoqué cela dans la section 1.2.3, en insistant sur le fait que pour des raisons de dysfonctionnements réguliers des anémomètres, en particulier pour les vitesses de vent faible, les créateurs de dispositifs DLR préféraient mesurer l'effet du vent de manière indirecte grâce à des mesure de température ou de caractéristiques mécanique du câble, ce qui fait que les directions et vitesses du vent sont en fait des données inaccessibles pour la plupart des utilisateurs du DLR. Cela pousse alors déjà à montrer qu'une des hypothèses des articles évoqués est à remettre en cause : dans la plupart des cas, on ne peut pas utiliser 3 prévisions probabilistes de paramètres météorologiques pour la prévision du DLR, mais seulement 2, l'une étant la prévision de l'effet de convection et l'autre celle de la température.

Les méthodes proposées ici, basées sur la prévision de plusieurs paramètres météorologiques, ne devrait alors théoriquement être basée que sur la prévision de deux variables météorologiques, la température et le nombre de Nusselt.

Un autre point relatif à ces études est que à l'exception de [81], la plupart des études faites avec une approche tenant compte de plusieurs paramètres météorologiques ne prennent pas en compte les corrélations possibles entre les erreurs des prévisions des différents paramètres utilisés, considérant les erreurs de prévision comme complètement décorréélées lorsque la simulation de Monte Carlo est faite. La modélisation de ces corrélations peut être difficile et peut avoir un impact significatif sur les performances des modèles de prévision, ce qui peut rendre plus attractive une approche de prévision directe du DLR sans étape intermédiaire.

### **1.5.2.3. Prévisions faites à base de méthodes d'intelligence artificielle**

Les raisons que l'on vient d'évoquer dans le paragraphe précédent peuvent justifier le fait de travailler avec des modèles non-paramétriques fournissant directement des prévisions de RTL.

Dans [90], deux telles approches sont proposées pour initialement fournir des valeurs de DLR à partir de données d'entrée qui sont des mesures de paramètres météorologiques, de courant et de température, le modèle physique n'étant alors pas considéré en raison de la nécessité de la prise en connaissance de certains paramètres de ligne qu'il implique. Les modèles utilisés sont une régression des moindres carrés partiels [91] et un réseau de neurones. Après avoir évalué leur modèle dans leur capacité à fournir des valeurs de DLR, les auteurs proposent alors de réutiliser leur modèle pour des prévisions du DLR à court-terme. Les prévisions sont des prévisions moyennes, et sont évaluées à l'aide des indices de corrélation et d'erreur quadratique. Il est à signaler que le cas d'étude utilisé dans cette étude est le même que celui que nous avons utilisé dans les chapitres 2 et 3.

On citera aussi [48], une étude faite dans notre laboratoire et qui a servi de point de départ à cette thèse. Dans cette étude, une première approche met en concurrence plusieurs modèles en terme de prévision moyennes : un modèle linéaire généralisé [92], une régression multivariée par spline adaptative (MARS) [93] et une forêt aléatoire (RF) [94]. Ces modèles sont testés sur le même cas d'étude irlandais que dans [90], et sont évalués par rapport à leur capacité à fournir des prévisions moyennes du DLR, avec l'erreur absolue et le biais, les modèles MARS et RF fournissant alors des performances équivalentes. Par la suite, un modèle probabiliste de Quantile Regression Forest (QRF) est proposé [95], permettant de fournir des prévisions à bas quantile.

### **1.5.3. Discussion sur l'état de l'art des modèles de prévision du DLR**

Dans un premier temps, on constate dans la littérature un manque important de modèles de prévision probabilistes permettant de fournir des prévisions probabilistes du DLR de manière directe. Une grande partie des types de prévisions sont en effet des prévisions paramétriques de variables météorologiques réutilisées avec le modèle physique pour générer des prévisions probabilistes du DLR. Des modèles différents, comme des modèles non paramétriques fournissant une prévision directe du DLR, auraient cependant plusieurs intérêts : il serait possible de modéliser des relations plus complexes entre des données d'entrée et des sorties, la prise en compte des corrélations entre les erreurs des différents paramètres météorologiques n'étant pas à modéliser, et il serait aussi possible de paramétrer ces modèles en accord avec des fonctions objectif différentes.

Ensuite, on constate un certain manque par rapport à l'évaluation des modèles de prévision. Jusqu'à récemment, la plupart des indices d'évaluation des prévisions étaient des indices d'évaluation déterministes, ici le biais et le critère de l'erreur absolue (MAE). A l'exception de [81] où le CRPS est utilisé, et ce pour évaluer des prévisions météorologiques intermédiaires et non des prévisions du DLR, on constate que des indices d'évaluation standard de modèles probabilistes ne sont pas utilisés.

De manière générale, les auteurs ne considèrent que la fiabilité comme paramètre déterminant, comme par exemple dans [72] ou [73] où seul ce critère est discuté, les résultats relatifs à la finesse n'étant pas présentés. Deux points justifient cette approche d'évaluation simple.

Tout d'abord, les prévisions sont généralement utilisées avec des quantiles fixés et contraignants, et le critère de risque de surestimation des prévisions apparaît comme le plus important, devant les gains potentiels qui évoluent eux avec la finesse. Ensuite, les études sur les modèles de prévision DLR ne présentent généralement qu'un modèle de prévision probabiliste pour le DLR. Même dans [48], où 4 modèles de prévisions moyennes du DLR sont présentés et comparés, un seul modèle probabiliste est présenté. Or, avec un seul modèle présenté, il est difficile de tirer des conclusions d'indices comme la finesse ou le CRPS, mais il est en revanche possible de dire si la fiabilité est satisfaisante ou non. Dans le chapitre 5, nous discutons les limites de cette approche en nous basant sur des comparaisons de modèles de prévisions faites au travers d'analyses économiques basées sur des simulations de réseau électrique.

Par la suite du développement des modèles de prévision, nous ferons aussi remarquer qu'il est souvent proposé dans la littérature de traiter les prévisions fournies par les modèles de manière à limiter les risques.

De telles modifications proposées dans la littérature peuvent être discutables, comme par exemple dans [48] ou [72] où les auteurs proposent une règle générale pour l'utilisation des prévisions en pratique : les gestionnaires de réseau auraient à utiliser des prévisions du RTLRL avec des quantiles fixés à 10%, et soustrairaient l'erreur de surestimation maximale observée sur une période de 6 mois. Or des modèles probabilistes plus performants sur des indices statistiques comme le CRPS, et donc pouvant générer des erreurs plus importantes, pourraient ainsi se retrouver pénalisés. Pour illustrer, avec une telle méthode, une prévision probabiliste ne générant que des prévisions égales au SLR pourraient alors fournir de meilleurs résultats économiques que des prévisions fournies par un modèle comme une régression quantile par forêt aléatoire, en raison de la capacité du modèle à ne faire que des erreurs à magnitude faible et donc peu modifiées par rapport aux autres prévisions.

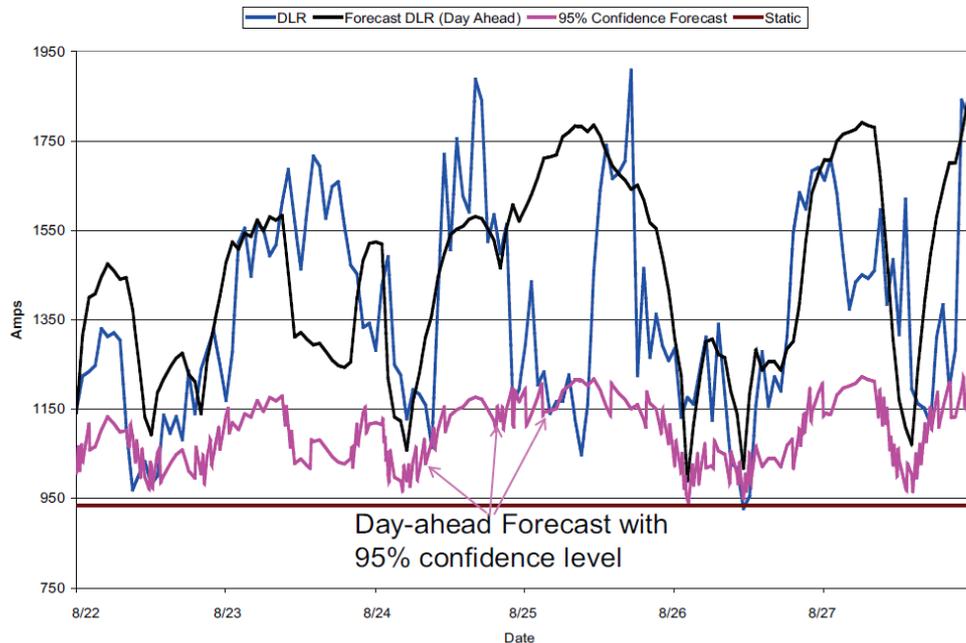
## **1.6. Utilisation des prévisions dans des planifications de production d'électricité**

### **1.6.1. Utilisation de niveaux de probabilité fixés**

Lorsque l'on s'intéresse à l'utilisation en pratique des prévisions DLR dans la littérature, on remarque une forte prééminence d'études proposant l'utilisation de prévisions de quantiles fixés. L'idée est de proposer aux gestionnaires de réseau d'utiliser des prévisions ayant des probabilités de dépasser les observations choisies arbitrairement et statiques, et par la suite de modifier des plannings de production d'énergie en accord avec les prévisions du DLR, sans considérer de potentielles rétroactions. On pourra

ici citer des articles proposant de telles méthodologies d'utilisation des prévisions DLR, les probabilités fixes choisies étant :

- 1% dans [73].
- 2% dans [70]–[72].
- 2,5% dans [74], [75] (**Figure 1-11**).
- 10% dans [48].
- Des quantiles choisis entre 1%, 5% et 10% dans [51], [76].



**Figure 1-11.** Illustration de prévisions DLR quantile, avec une probabilité d'être supérieure à l'observation future fixée à 2,5%, telles que présentées dans [74]

Le choix du quantile peut être déterminant dans les gains potentiels offerts par le DLR, ainsi que les risques associés à l'implémentation d'une nouvelle source d'incertitude. Cela est montré dans [51], où l'on constate que l'utilisation de quantiles à 10% plutôt qu'à 1% pour les prévisions doublerait les bénéfices financiers et augmenterait sensiblement les risques, mais que ces risques seraient alors du même ordre de grandeur que ceux associés à l'utilisation du SLR.

Cette approche est dans un sens statique, ce qui est surprenant pour une technologie visant à remplacer une approche statique de la définition de l'ampacité d'une ligne par une approche dynamique. Certains auteurs essaient alors de prendre en compte des caractéristiques de prévisions variables, adaptées aux caractéristiques du réseau électrique, pour définir une prévision du DLR optimale.

## 1.6.2. Optimisations stochastiques prenant en compte le DLR

Comme nous l'évoquions précédemment, le choix d'une prévision du DLR optimale est fait à l'aide de résolution de problèmes d'optimisation stochastique à deux étapes, où des activations de réserve sont considérées pour réagir face à des erreurs de prévision.

Dans [96], à partir de prévisions virtuelles pour des horizons de 3 heures et de 24 heures, les auteurs considèrent un dispatch tenant compte de potentielles activations de réserve en cas d'erreurs de

prévisions du DLR. Par la suite, une méthodologie similaire est décrite dans [60], mais des erreurs de prévisions éoliennes sont aussi considérées. Ces deux études visent à augmenter le bien-être social, dans le sens où elles cherchent à diminuer au maximum les coûts de gestion du système.

Les études évoquées ne considèrent pas de dépassement de la valeur du DLR par le courant passant dans les lignes considérées, là où les gestionnaires de réseau peuvent accepter des dépassements de magnitude faible comme ils le font avec le SLR. Cela est pris en compte dans [61]–[63]. Ici les auteurs considèrent un problème d’optimisation stochastique en considérant des coûts associés à des situations où le courant dans une ligne serait supérieur à la valeur du DLR. Ces coûts évoluent avec la magnitude du dépassement de manière linéaire [61] ou quadratique [62], [63]. Dans [62], une forme exponentielle est aussi évoquée.

Ces études posent un problème dans leur faisabilité. Actuellement, les gestionnaires de réseau utilisent des approches conservatives pour les prévisions du DLR, des quantiles bas étant utilisés de manière à limiter le nombre d’opérations de recours nécessaires. Ici, les approches sont neutres au risque, et le fait de passer d’une approche conservative à de telles approches représenteraient une évolution importante pour le gestionnaire de réseau, et qui ne peut pas être considérée comme réaliste à court-terme. Il n’existe actuellement pas d’approches permettant de prendre en compte le fait que la méthodologie d’optimisation adaptée au DLR devrait respecter une aversion au risque de la part du gestionnaire de réseau similaire à celle associée aux approches conservatives initiales.

Pour conclure cet inventaire, on peut alors considérer trois types d’utilisation du DLR :

- Des prévisions du DLR à caractéristiques fixes et arbitraires, considérées la plupart du temps dans des cas où des rétroactions ne sont pas possibles. De telles méthodes limitent les bénéfices du DLR, mais limitent aussi les risques.
- Des prévisions DLR probabilistes utilisées dans des problèmes d’optimisation stochastique visant à maximiser le bien-être social, sans prendre en compte les motivations du gestionnaire de réseau. Les bénéfices des prévisions du DLR sont alors beaucoup plus importants, mais cela s’accompagne d’une explosion des termes pour lesquels les gestionnaires de réseau éprouvent de l’aversion, comme par exemple les coûts à la charge du gestionnaire de réseau, où alors le nombre de situations à risque important.
- Des prévisions DLR probabilistes utilisées dans des optimisations stochastiques visant à améliorer le bien-être social, mais en ajoutant des pénalités pour tenir compte de certains critères définis par le gestionnaire de réseau, comme l’aversion au risque. De telles méthodes n’existent actuellement pas dans la littérature.

## 1.7. Objectifs et démarche de la thèse

Cette thèse se focalise principalement sur les prévisions du Dynamic Line Rating, du point de vue de la création de modèles de prévision pour des horizons à court terme (6h-48h) et de l’application de ces prévisions pour améliorer la gestion du réseau électrique.

Dans un premier temps, nous avons constaté un manque important de méthodes de prévisions probabilistes adaptées aux particularités du problème de la prévision du DLR, utilisant des prévisions météorologiques et des observations terrain. Un tel modèle était proposé dans [48], dans le cadre d’un travail fait dans notre équipe, mais ce travail se focalisait principalement sur des modèles de prévisions déterministes. Or, ils manquent aux prévisions déterministes des propriétés importantes pour les

prévisions DLR, comme le fait que les prévisions DLR doivent avoir de faibles probabilités d'être surestimées.

Nous avons alors proposé de définir plusieurs modèles de prévision probabilistes adaptés au Dynamic Line Rating, pour des horizons de prévisions allant de quelques heures à quelques jours. Nous avons développé nos modèles à l'aide de données de stations météorologiques collectées au Royaume-Uni toutes les 5 minutes pour une période de 2 ans, et un historique de prévisions météorologiques associées pour des horizons allant de 0 à 48 heures.

Notre objectif était, par la mise en avant de plusieurs méthodes de machine learning déjà utilisées pour générer des prévisions dans le domaine de l'énergie, de pouvoir fournir une méthode de prévision du DLR aux performances validées par comparaison. Ces performances étaient évaluées dans un premier temps avec différents indices statistiques régulièrement utilisés dans le cadre de l'évaluation d'autres types de prévisions comme la prévision de la production éolienne. On fera remarquer qu'une difficulté que nous cherchions à dépasser était le fait qu'il n'existe pas de méthode standard d'évaluation de la qualité des prévisions du DLR. Par exemple, une grande partie de la littérature met en avant le critère de la fiabilité des prévisions probabilistes comme le critère déterminant, mais il n'existe pas d'étude validant la pertinence de cette approche. Notre travail visait alors aussi à discuter du développement d'un critère d'évaluation optimal pour évaluer des modèles de prévisions du DLR.

Comme cela est déjà observé pour d'autres types de prévision, les méthodes que nous proposons étaient généralement satisfaisantes pour fournir des prévisions quantiles de qualité pour des niveaux de probabilité supérieurs à 2%, mais il nous semblait aussi être intéressant de pouvoir aussi avoir des prévisions satisfaisantes pour des niveaux de probabilité encore plus faibles.

On se proposait alors par la suite de modifier les modèles proposés de manière à ce qu'ils soient en mesure de fournir des prévisions à très bas quantile satisfaisantes pour des applications ultérieures, lors de l'utilisation d'approches basées sur des optimisations stochastiques. On fera remarquer que cela ne pouvait pas passer par des paramétrages des modèles différents, des modèles comme des Random Forest n'étant pas capables d'extrapoler pour obtenir des prévisions à quantile très bas dès lors que des observations historiques extrêmes manquent. Nous avons alors plutôt travaillé avec des modélisations de queues de distribution paramétriques, qui furent utilisées pour modifier les prévisions quantiles fournies par des modèles de base pour des niveaux de probabilité inférieurs à un seuil donné.

Par la suite, nous nous sommes intéressés à l'utilisation de ces prévisions en pratique. Nous avons en effet montré que les méthodologies actuellement proposées dans la littérature étaient peu satisfaisantes : soit celles-ci sont statiques, les quantiles utilisés pour les prévisions étant fixés, et les bénéfices sont alors limités ; soit celles-ci sont dynamiques, mais sans prise en compte de la moindre aversion au risque de la part du gestionnaire de réseau, les approches n'étant alors pas réalistes par rapport à la plupart des utilisations du DLR. Nous souhaitons alors poser de manière claire les différents enjeux associés à l'utilisation des prévisions DLR pour le gestionnaire de réseau, et par la suite développer des méthodologies d'utilisation de prévisions DLR dans des approches optimisant le bien-être social tout en respectant des critères satisfaisants pour les gestionnaires de réseau.

Dans un premier temps, une méthodologie inspirée de travaux faits pour les énergies renouvelables était développée, pour le cas virtuel d'une interconnexion entre deux pays, ici la Belgique et la France, tenant compte de prévisions DLR fournies pour une station météorologique à la frontière entre ces deux pays, les coûts de l'électricité spot et les coûts de réserve. Cette approche fournissait un premier aperçu des

bénéfices possibles grâce au DLR mais avait plusieurs limites en raison des hypothèses simplificatrices posées.

Nous nous sommes alors intéressés à des études plus complètes, tenant compte de caractéristiques de réseau électriques et permettant de modéliser plus finement l'influence des modifications d'ampacité sur les dispatchs faits sur un réseau en accord avec les flux de puissance. L'objectif était de pouvoir, en accord avec ces cadres d'utilisation définis dans nos travaux, de pouvoir fournir des évaluations réalistes des bénéfices et des risques en accord avec de grands nombres de prévisions et de stratégies, le nombre total de combinaisons considérées étant de l'ordre du milliard. Une approche basée sur la définition et la résolution de problèmes d'optimisation stochastique n'était alors pas possible dans un délai raisonnable, et une approche alternative devait aussi être définie.

Cela a été fait avec la mise en place de tables de correspondance permettant d'approcher des résultats d'optimisations stochastiques et qui prenaient en compte des prévisions DLR, des caractéristiques de réseau électrique et différentes stratégies mises en place par le gestionnaire de réseau, traduisant son aversion à différents types de risque.

La finalité de cet outil était double : fournir une évaluation d'un nouveau cadre d'application aux prévisions DLR, et à partir de ce cadre, évaluer la valeur des modèles de prévisions proposés dans la première partie de cette thèse.

## 1.8. Structure du manuscrit

Dans ce **Chapitre 1** introductif, nous avons présenté les différents aspects relatifs au DLR, à la nature de la technologie et aux bénéfices pouvant y être associés. Par la suite, nous nous sommes particulièrement focalisés sur les prévisions du DLR et leur utilisation par le gestionnaire de réseau par une analyse de l'état de l'art, et nous avons montré certains manques, que ce soit sur l'absence d'utilisation de méthodes de prévision du DLR adaptées aux particularités du problème, ou le manque de recherche sur des méthodes d'utilisation des prévisions satisfaisantes. Ces différents points ont structuré le travail de cette thèse.

Dans le **Chapitre 2**, nous proposons différentes formes de modèles de prévision du DLR développés avec des prévisions météorologiques et des données de stations météorologiques collectées pendant une durée de 2 ans. Nous discutons le paramétrage de ces modèles, celui-ci pouvant être différent lorsque l'on se focalise sur des quantiles que l'on pourrait qualifier de médians ou des quantiles bas, et nous évaluons ces différents modèles en accord avec des indices d'évaluation statistique traditionnels ou des indices plus adaptés à des quantiles bas

Par la suite, dans le **Chapitre 3**, nous proposons de réutiliser les modèles du chapitre 2, et de les améliorer de manière à ce que les prévisions à quantiles extrêmes fournies par les modèles soient satisfaisantes. Cela passe par deux méthodes : soit l'utilisation de la théorie des valeurs extrêmes pour extrapoler des prévisions à quantiles très bas (0,1%-1%) à partir des prévisions à bas quantile (1%-5%), soit l'utilisation de fonctions exponentielles dont les paramètres sont définis à partir de données tirées d'un échantillon d'entraînement découpé en clusters.

Suivant ce développement de modèles, nous nous sommes intéressés à leur application. Une première approche simple a été proposée dans le **Chapitre 4**, où à partir de données de marché, nous avons démontré l'intérêt d'utiliser l'information du marché de l'électricité pour fixer une prévision DLR

optimale, de manière similaire à ce qui peut être fait pour des prévisions d'énergies renouvelables. Cette approche, dans le développement des équations, permettait aussi d'illustrer les différents transferts financiers entre les gestionnaires de réseau et les autres acteurs, et ainsi de montrer l'intérêt de la mise en place de stratégies alternatives par le gestionnaire de réseau.

Enfin, dans le **Chapitre 5**, nous avons considéré un problème d'optimisation stochastique modifié pour illustrer plusieurs stratégies différentes possibles pour le gestionnaire de réseau, en comparaison à des méthodes standard, que ce soit l'utilisation de quantiles fixés ou d'optimisation non averse au risque. Nous avons pu ainsi démontrer l'intérêt de notre méthodologie, évaluer les performances des différents modèles de prévision d'un point de vue économique et enfin montrer l'intérêt de développer des prévisions à quantile extrême fiables.

Les conclusions de nos travaux de même que des perspectives pour la suite sont finalement présentées dans le **Chapitre 6**.

# CHAPITRE 2

## Prévision du Dynamic Line Rating à court-terme

---

### 2.1. Introduction

Le développement d'un modèle de prévision du DLR adapté aux contraintes opérationnelles est le premier objectif que nous proposons d'aborder. Cette problématique a été précédemment étudiée par notre équipe dans [48], où trois différentes méthodes étaient évaluées et comparées en fonction de leur habilité à fournir des prévisions DLR déterministes. Dans cette étude, deux types de modèles étaient mis en avant, fournissant tous deux des prévisions équivalentes en termes de biais et d'erreur absolue, un modèle random forest et une régression multivariée par spline adaptative. Les conclusions relatives aux qualités de ces méthodes pour des prévisions déterministes du DLR ne sont cependant pas généralisables à des prévisions probabilistes, que de tels modèles peuvent aussi fournir avec des régressions quantiles. Cette absence de généralisation possible est en particulier à souligner pour le cas de la génération des prévisions à bas quantile, ces types de prévisions étant nécessaires pour des opérations de planifications prenant compte du DLR.

Dans ce chapitre, comme dans [48], nous proposons aussi une comparaison de modèles de prévision, mais ici en nous intéressant non à des prévisions déterministes mais à des prévisions probabilistes. L'objectif est de pouvoir mettre en avant les problématiques particulières associées aux performances des modèles de prévision du DLR, et de pouvoir en tirer un modèle de prévision satisfaisant ainsi que les raisons expliquant les performances des modèles obtenus.

Pour réaliser cette étude, des données météorologiques collectées sur des stations météo pendant deux ans au Royaume-Uni, sont utilisées, en complément de prévisions météorologiques historiques. On se propose alors à l'aide de ces données de développer 5 modèles de prévision différents. Par la suite, les différentes prévisions générées par les modèles proposés sont évaluées avec des indices usuels d'évaluation de prévisions probabilistes, et nous sélectionnons avec ceux-ci des modèles qui seront utilisés dans les chapitres suivants.

## 2.2. Cas d'étude

Les différentes méthodologies de prévision développées dans ce chapitre sont testées pour la problématique du DLR sur un premier cas d'étude constitué d'une ligne opérée à 110 kV au Royaume-Uni. Ce cas d'étude est aussi considéré dans les articles [48], [97]–[100].

Le câble de la ligne est un câble Lynx 175 mm<sup>2</sup> aux caractéristiques techniques conformes aux brochures techniques, reprises sur le **Tableau 2-1**. Les considérations relatives au calcul de la flèche mécanique pour obtenir la valeur de la température maximale ne sont pas prises en compte, et cette température est arbitrairement fixée à 75°C.

**Tableau 2-1.** Caractéristiques techniques du câble Lynx 175 mm<sup>2</sup>

Nominal aluminium area	Equivalent copper area	Stranding and wire diameter		Overall diameter	Total area			Weights			Calculated breaking load	Maximum DC resistance at 20°C
		Aluminium	Steel		Aluminium	Steel	Total	Aluminium	Steel	Total		
mm <sup>2</sup>	mm <sup>2</sup>	mm	mm	mm	mm <sup>2</sup>	mm <sup>2</sup>	mm <sup>2</sup>	kg/km	kg/km	kg/km	kN	Ω/km
175	113	30/2,79	7/2,79	19,53	183,4	42,79	226,2	507	335	842	79,8	0,1576

Le long de la ligne étudiée, 8 stations météorologiques ont été installées, numérotées de 1 à 8, et distantes en moyenne de 4 km. Les deux extrémités de la ligne sont distantes de 35km.

Des mesures ont été faites pendant 2 ans, sur la période 2009-2010, toutes les 5 minutes. Les paramètres météorologiques enregistrés ont été la vitesse du vent (m/s), la direction du vent (rad), l'irradiation solaire globale (W/m<sup>2</sup>) et la température ambiante (K).

Des prévisions météorologiques fournies par le Centre Européen pour les Prévisions Météorologiques à Moyen terme (ECMWF) sont considérées pour la même période, la résolution spatiale de ces prévisions étant de 0,125°. Les horizons des prévisions utilisées varient entre 0 et 48 heures, avec un pas de temps de 3 heures. L'ensemble des horizons étant des multiples de trois heures, on complète pour les horizons manquants à l'aide d'interpolations linéaires, de manière à avoir une prévision pour chaque horizon considéré.

Les variables considérées parmi les prévisions météorologiques sont les vitesses de vent zonale et méridionale à 10m (m/s), l'irradiation solaire globale (W/m<sup>2</sup>) et la température ambiante (°C).

L'ensemble de données obtenu est divisé en deux ensembles, chacun représentant un an de données. Le premier ensemble est utilisé pour entraîner les modèles de prévision, et le deuxième pour évaluer les modèles obtenus. Ces structures de données simples permettent de tester plusieurs modèles rapidement, ce que nous souhaitons faire dans ce chapitre, et des structures avec des fenêtres glissantes seront à l'inverse privilégiées dans les chapitres suivants. On considère que les prévisions sont tous les jours faites pour chaque station, à midi, pour des horizons allant de 1 heure à 48 heures.

### 2.2.1. Définition du Static Line Rating

La définition d'une valeur du SLR permet par la suite d'évaluer les modèles de prévision dans leur capacité à proposer des améliorations par rapport au SLR.

Pour le cas d'étude considéré, une première valeur constante du Static Line Rating est calculée à l'aide du modèle physique (1-22) défini dans le chapitre 1, et avec des valeurs constantes de variable météorologiques contraignantes pour une saison et qui sont définies dans [27]. On a considéré ici comme valeurs de RTLRL les valeurs minimales de RTLRL calculées pour chaque instant sur les 8 stations étudiées. On peut alors mesurer les fréquences de dépassement des valeurs de RTLRL par rapport aux valeurs traditionnelles de SLR (Cas A - **Tableau 2-2**).

Comme dans [27], on constate des fréquences de dépassement du SLR importantes, d'autant plus que contrairement à cette étude qui ne considère qu'une station météo, on considère ici les valeurs minimales sur un ensemble de stations météorologiques. En plus de sérieusement remettre en question la capacité des valeurs de SLR choisies à assurer un fonctionnement sans risque, cette fréquence élevée est un problème pour notre étude car il est alors difficile de pouvoir réussir à obtenir des avancées en termes d'augmentation d'ampacité grâce au DLR, en particulier avec des prévisions à quantile bas en J-1.

Deux solutions peuvent être proposées pour fournir de nouvelles valeurs de SLR respectant des critères de sécurité satisfaisants. La première est de modifier les critères météorologiques utilisés. Ainsi, on pourrait fixer l'irradiation solaire à  $1000 \text{ W/m}^2$  et la direction du vent à  $0^\circ$ , pour avoir des valeurs de SLR plus faibles, passant par exemple de 651 A à 420 A pour l'hiver avec ces modifications. Il est à faire remarquer que les valeurs présentées dans [27] sont d'ailleurs étonnantes au regard de ces changements proposés : l'irradiation solaire considérée pour une situation critique correspond à une situation de nuit, et le vent est défini comme perpendiculaire à la ligne, ce qui revient alors à utiliser deux paramètres peu contraignants.

La deuxième méthode, que l'on utilisera dans notre travail, est de définir le SLR à partir de critères de fréquence. Pour chaque saison, on considère l'ensemble des valeurs de RTLRL calculées comme précédemment décrit, et on sélectionne le premier percentile pour les valeurs associées à chaque saison. Un abaissement important des valeurs du SLR est alors observé, montré en deuxième partie du **Tableau 2-2**, et ce sont ces valeurs que nous utiliserons par la suite.

**Tableau 2-2.** Comparaison pour la sélection des valeurs du SLR : Cas A, utilisation de valeurs de SLR fixées à l'aide de paramètres contraignants arbitrairement sélectionnés ; Cas B, utilisation de valeurs de SLR choisies de manière à rester inférieures au RTLRL 99% du temps

		Température ambiante (°C)	Vitesse du vent (m/s)	Radiation solaire (W/m <sup>2</sup> )	Direction du vent (°)	SLR (A)	Fréquence où le SLR > RTLRL (%)
A	Printemps/ Automne	9	0,5	0	90	623	38,9
	Eté	20	0,5	0	90	574	40,5
	Hiver	2	0,5	0	90	651	61,6
B	Printemps/ Automne	-	-	-	-	451	1,0
	Eté	-	-	-	-	410	1,0
	Hiver	-	-	-	-	472	1,0

## 2.2.2. Section critique de la ligne

On rappelle que la section critique d'une ligne est la section de ligne où la température du câble est la plus élevée, cette position dépendant des conditions météorologiques. L'obtention de cette localisation est généralement faite à partir de données issues d'un nombre d'appareils de mesure limité, comme c'est ici le cas avec les différentes stations météorologiques utilisées. Pour l'étude des prévisions DLR, une simplification est régulièrement faite en fixant cette position toujours au même endroit [48].

Pour discuter cette hypothèse, on représente sur le **Tableau 2-3** les fréquences des situations où l'ampacité calculée en une station correspond à l'ampacité minimale des 8 stations considérées,  $\text{fréq}_{\min}(\text{station})$ .

**Tableau 2-3.** Fréquence des situations où l'ampacité calculée en une station donnée est la valeur minimale obtenue pour l'ensemble des stations.

Station considérée	$\text{fréq}_{\min}(\text{station})$ (%)
1	4,7
2	9,9
3	39,6
4	5,7
5	8,0
6	18,6
7	6,9
8	6,8
3_115%	75,1
3_105%	89,9
3_101%	96,1

Comme on peut le voir, une station apparaît comme prépondérante par rapport aux autres, la station 3, où l'ampacité calculée est l'ampacité minimale pour les 8 stations dans 40% des cas.

L'utilisation de cette seule station pour calculer l'ampacité d'une ligne entraînerait alors une situation où dans 60% des cas, l'ampacité calculée ne serait pas correcte. En reprenant [44], cette fréquence devrait être comprise entre 5% à 15% pour être en accord avec des critères opérationnels.

Le fait de travailler avec une seule station météorologique est alors critiquable, mais cette critique est à relativiser : dans [44], les valeurs d'ampacité utilisées ne sont pas modifiées, et les auteurs considèrent que les valeurs d'ampacité sont égales à la valeur minimale des ampacités calculées pour les stations. Or, en pratique, des seuils sont régulièrement fixés sur les valeurs que le DLR peut prendre. Ainsi, dans [74], les auteurs imposent au DLR de rester compris entre la valeur du SLR et 115% du SLR pour des raisons de sécurité.

En reprenant des seuils bas et hauts pour l'ampacité de 100% et 115% du SLR (cas 3\_115%), l'ampacité calculée à la station 3 est différente de l'ampacité de la ligne non plus 60% du temps, mais 25%. Pour des seuils hauts plus faibles, par exemple 105% et 101% du SLR (les cas 3\_105% et 3\_101%), cette fréquence baisse alors à 10% et 4%.

Il est alors possible de juger que les résultats de valeur de DLR seraient relativement proches, que l'on considère plusieurs stations ou une seule, et nous maintenons dans ce chapitre l'hypothèse que chaque station météorologique, quand elle est considérée, est toujours localisée sur la position de la section critique de la ligne.

## 2.3. Propositions de modèles de prévision probabilistes

### 2.3.1. Description des modèles

En introduction, nous avons présenté les prévisions quantiles et probabilistes. Pour rappel, une prévision probabiliste d'une variable  $Y_{t+h}$  fournit l'ensemble des valeurs possibles de  $Y_{t+h}$  avec les probabilités associées. On peut considérer qu'une prévision probabiliste est l'ensemble des prévisions quantiles  $\tau$ ,  $\hat{Y}_{t+h|t}^\tau$ , avec  $\tau \in [0,1]$  :

$$P(\hat{Y}_{t+h|t}^\tau > Y_{t+h}) = \tau \quad (2-1)$$

Ici, on s'intéresse à des méthodologies permettant d'obtenir des prévisions quantiles pour un quantile donné fonction de données d'entrée  $X_t$ ,

$$\hat{Y}_{t+h|t}^\tau = F_h^\tau(X_t) \quad (2-2)$$

De telles prévisions peuvent soit être obtenue de manière directe en minimisant la fonction de perte Pinball, soit en la tirant d'une prévision probabiliste. Ici, nous proposons deux méthodes fournissant directement une prévision quantile (les QLR et GBRT) et trois fournissant une prévision probabiliste dont est extraite une prévisions quantile (les KDE, MDNN et QRF).

#### 2.3.1.1. Régression Linéaire Quantile (QLR- Quantile Linear Regression)

Le modèle de la régression linéaire quantile a été utilisé récemment pour la prévision du DLR dans [83], ce pour des prévisions à horizon d'une heure. L'utilisation de ce modèle pour des horizons à très court-terme nous a motivé à utiliser ce type de modèle pour le développement de nos prévisions.

La régression quantile [101] vise à permettre l'obtention directe d'une prévision quantile  $\hat{Y}_{t+h|t}^\tau$ , et non pas d'une densité de probabilité.

Pour un niveau de probabilité donné  $\tau$ , la régression est faite de manière à réduire la fonction de perte Pinball  $L_{\text{Pinball}}^\tau$  définie par :

$$L_{\text{Pinball}}^\tau(Y_{t+h}, \hat{Y}_{t+h|t}^\tau) = \begin{cases} (1 - \tau) \cdot (\hat{Y}_{t+h|t}^\tau - Y_{t+h}) & \text{si } Y_{t+h} < \hat{Y}_{t+h|t}^\tau \\ \tau \cdot (Y_{t+h} - \hat{Y}_{t+h|t}^\tau) & \text{si } Y_{t+h} \geq \hat{Y}_{t+h|t}^\tau \end{cases} \quad (2-3)$$

Nous travaillons pour chaque horizon de prévision avec 99 prévisions quantiles, une pour chaque percentile. Le modèle pour chaque horizon étant différent, il n'est pas rare de voir des prévisions quantiles  $\tau^+$  être inférieures à des prévisions quantiles  $\tau^-$ ,  $\hat{Y}_{t+h|t}^{\tau^-} > \hat{Y}_{t+h|t}^{\tau^+}$  avec  $\tau^+ > \tau^-$ . On résout cela en classant les prévisions quantiles dans un ordre croissant, et en affectant ensuite à chaque prévision un nouveau quantile, selon que sa place a été modifiée ou non.

La fonction  $\hat{F}_h^T$  est ici définie comme une fonction linéaire des entrées  $X_t$  (2-4), cette approche étant utilisée dans [83] :

$$F_h^T(X_t) = A_h \cdot X_t + b_h \quad (2-4)$$

où  $A_h \in \mathbb{R}^{1,d}$ ,  $X_t \in \mathbb{R}^{d,1}$ ,  $b_h \in \mathbb{R}$  et  $d$  est le nombre de variables.

### 2.3.1.2. Densité mélange paramétrée par réseau de neurones (MDNN – Mixture Density Neural Network)

Le modèle de la densité mélange paramétrée par réseau de neurones a été choisi de telle manière qu'un modèle paramétrique soit proposé parmi les différents modèles définis, les sorties des modèles étant des densités de probabilité définies avec un nombre fini d'éléments. De tels modèles ont des structures simples comme le modèle de la régression quantile, mais permettent d'éviter des phénomènes comme des croisements de prévisions quantiles précédemment évoqués. Ils peuvent aussi offrir une plus grande stabilité pour les quantiles bas que le modèle QLR, les prévisions quantiles fournies par le MDNN étant associée à une prévision probabiliste et n'étant pas obtenue seule à partir de la minimisation d'une fonction de perte.

De plus, ils offrent des possibilités de paramétrage qui sont intéressantes pour l'étude de la prévision DLR, par le choix du nombre de densités, de neurones ou de variables d'entrée, qui permettent d'obtenir des prévisions adaptées à différentes définitions d'objectifs des gestionnaires de réseau.

Une densité mélange  $g$  est une densité de probabilité issue d'une combinaison convexe de plusieurs lois de densité  $f_i$  aux paramètres  $\theta_i$  :

$$g(\theta_1, \dots, \theta_p) = \sum_{i=1}^p \alpha_i \cdot f_i(\theta_i) \quad (2-5)$$

$$\sum_{i=1}^p \alpha_i = 1 \quad (2-6)$$

Dans le cadre de notre travail, les fonctions  $f_i$  sont définies comme gaussiennes, aux paramètres d'espérance mathématique  $\mu_i$  et d'écart-type  $\sigma_i$  (2-7) :

$$g(\theta_1, \dots, \theta_p) = \sum_{i=1}^p \alpha_i \cdot f_{\text{Gaussian}}(\mu_i, \sigma_i) \quad (2-7)$$

Avec le modèle proposé, les densités de probabilité  $\hat{f}_{t+h|t}$  associées aux prévisions du DLR sont considérées comme de telles densités, dont les paramètres dépendent de variables d'entrée  $X_t$ .

$$\hat{f}_{t+h|t}(X_t) = \sum_{i=1}^p \alpha_i(X_t) \cdot f_{\text{Gaussian}}(\mu_i(X_t), \sigma_i(X_t)) \quad (2-8)$$

La valeur des paramètres  $\mu_i, \sigma_i$  dépendants de  $X_t$  est définie à l'aide d'un réseau de neurones à la structure simple définie dans [102], ici un perceptron monocouche, entraîné de manière à maximiser la fonction de vraisemblance sur un échantillon d'entraînement. On représente sur la **Figure 2-1** une telle structure, pour le cas à deux neurones et 2 densités pour le mélange.

Chaque fonction  $g_i$  associée à un neurone est une fonction tangente hyperbolique, en fonction d'une somme linéaire des paramètres d'entrée  $x_{k,t}$  :

$$g_i(X_t) = \tanh(c_i + A_{g_i} \cdot X_t) \quad (2-9)$$

où  $c_l \in \mathbb{R}$ ,  $A_{g_l} \in \mathbb{R}^{1,d}$ .

On trouve alors pour chaque paramètre de sortie  $a_j^i$  la fonction suivante :

$$a_i^j(X_t) = b_i^j + \sum_{l=1}^{n_h} w_{il}^j g_l(x) + A_{a_i^j} \cdot X_t \quad (2-10)$$

où  $b_i^j, w_{il}^j \in \mathbb{R}$ ,  $A_{a_i^j} \in \mathbb{R}^{1,d}$ .

Les paramètres  $a_i^j(x)$  sont ensuite modifiés, de telle manière que le modèle respecte les contraintes de positivité et les contraintes relatives à la somme des poids des densités devant être égales à 1 :

$$\pi_i(x) = \frac{\exp(a_i^0(x))}{\sum_{k=1}^p \exp(a_k^0(x))} \quad (2-11)$$

$$\mu_i(x) = a_i^1(x) \quad (2-12)$$

$$\sigma_i(x) = \log\left(1 + \exp(a_i^2(x))\right) \quad (2-13)$$

Le modèle compte deux paramètres, le nombre de neurones  $n_h$  et le nombre de densités  $p$ . Ces paramètres seront discutés plus tard dans ce chapitre. Il est aussi à signaler que ce modèle peut avoir des difficultés à converger. Pour éviter les écueils associés à ce problème, on entraîne un nombre de modèles initiaux relativement important, ici 200, chacun avec une configuration de départ différente.

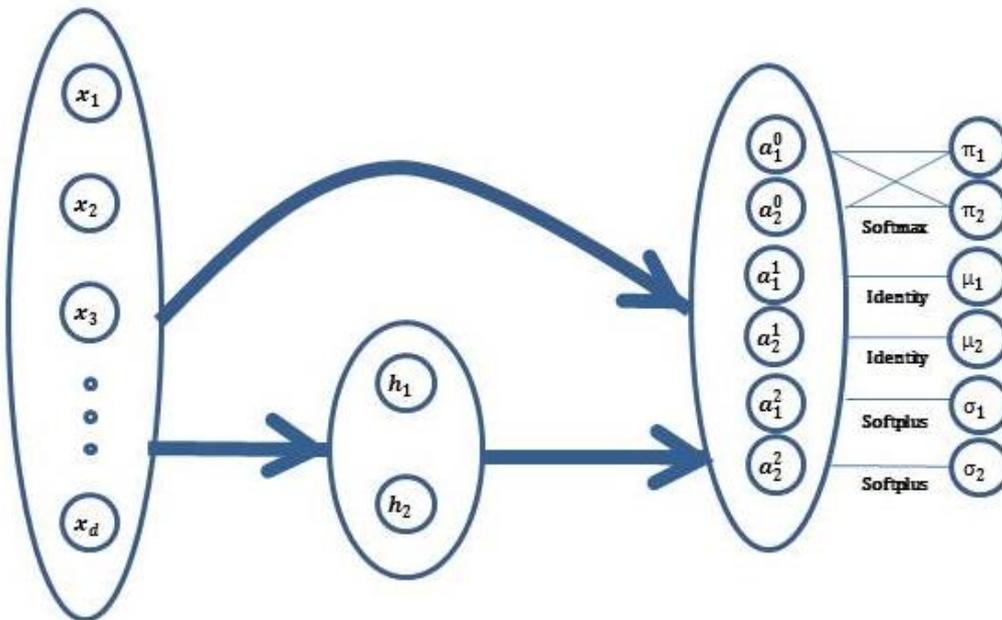


Figure 2-1. Schéma d'un modèle de densité mélange paramétrée par réseau de neurones.

### 2.3.1.3. Estimation par noyau (KDE – Kernel Density Estimator)

L'estimation de densités par noyau est une approche régulièrement utilisée pour la prédiction de la production d'énergie éolienne [103]–[105], la production d'énergie solaire [106] ou la charge [107].

Contrairement au MDNN, cette méthode est non-paramétrique et peut permettre de modéliser des relations plus complexes. De plus, contrairement aux méthodes ensemblistes que nous présenterons après, ce modèle fournit des densités de probabilité pouvant extrapoler sur les quantiles extrêmes, là où

les méthodes ensemblistes fixent des extremums. Le fait que cette méthode, pourtant fréquemment utilisée dans le cadre de problématiques énergétiques, n'est pas utilisée pour la prévision du DLR nous a motivé à la sélectionner.

L'estimation par noyau [108] est une méthode non-paramétrique permettant d'estimer la densité de probabilité d'une variable aléatoire. Considérant l'ensemble des points  $X_1, \dots, X_n$  d'un ensemble d'apprentissage, la densité de probabilité  $\hat{f}_{t+h|t}$  fournie par l'estimateur est :

$$\hat{f}_{t+h|t}(X_t) = \frac{1}{n} \sum_{i=1}^n K_H(X_t - X_i) \quad (2-14)$$

Où  $K_H$  est un noyau, et  $H$  est une matrice de lissage définissant les caractéristiques du noyau. Plusieurs fonctions peuvent être utilisées pour définir le noyau, et après plusieurs tests, une fonction gaussienne est sélectionnée. La matrice de lissage, elle, est ici définie comme une matrice identité multipliée par un paramètre de lissage  $H_{ii}$ .

On considère deux méthodologies pour obtenir ce paramètre. La première est basée sur la règle de Silvermann fournissant les paramètres de  $H$  si celle-ci est diagonale. En normalisant chaque variable par rapport à l'écart-type, on obtient alors une matrice identité multipliée par un paramètre  $h$  :

$$\sqrt{H_{ii}} = \left( \frac{4}{d+2} \right)^{\frac{1}{d+4}} \cdot n^{\frac{-1}{d+4}} \cdot \sigma_i \quad (2-15)$$

Où  $d$  est le nombre de variables,  $n$  est le nombre de points et  $\sigma_i$  est l'écart-type de la  $i^{\circ}$  variable.

Une deuxième solution est de trouver le paramètre  $H_{ii}$  à l'aide d'une k-validation croisée, de manière à maximiser la vraisemblance pour les observations de l'essai d'entraînement.

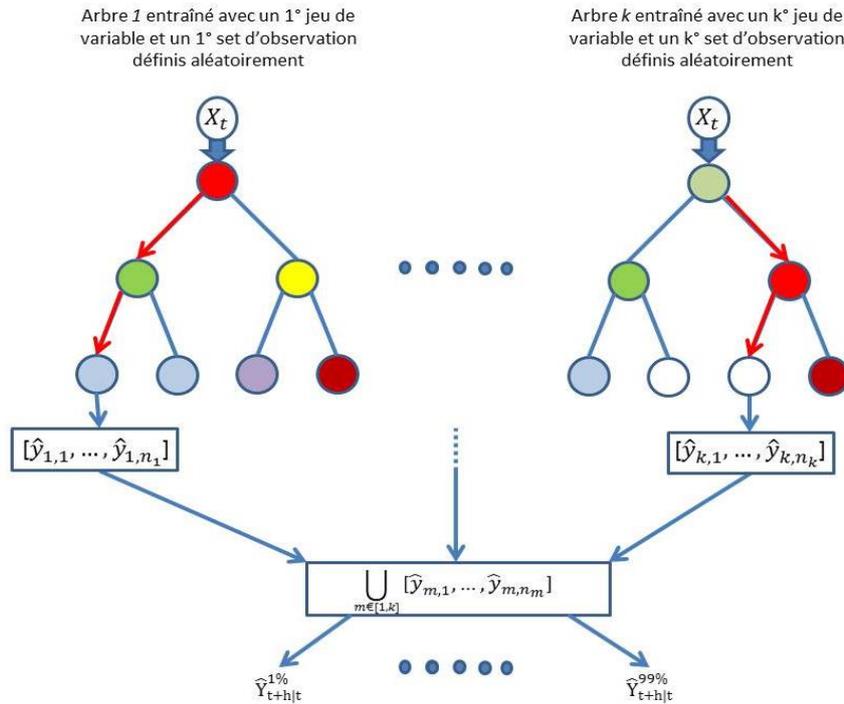
Le choix de l'utilisation de la règle de Silvermann ou d'une validation croisée est discuté dans la section 2.4.2.

#### 2.3.1.4. Regression quantile par forêt aléatoire (QRF – Quantile Regression Forest)

Pour le cas de la prévision DLR, le modèle de la régression quantile par forêt aléatoire [95] a une faiblesse notable : il est incapable de prévoir des valeurs inférieures au minimum des réalisations passées, là où les modèles précédemment évoqués extrapolent. Cependant, il est proposé dans [48] de les utiliser pour des prévisions DLR. De plus, cette méthode offre de bonnes performances, et apparaît dans plusieurs compétitions internationales [106]. Ces raisons nous motivent à considérer aussi cette approche.

Cette méthode est une méthode ensembliste qui génère un ensemble de  $k$  arbres décisionnels, chacun entraîné sur un sous-ensemble de points sélectionnés de manière aléatoire avec un processus de bagging. De plus, chaque arbre est aussi entraîné avec un sous-ensemble de variables sélectionnées de manière aléatoire.

A partir de l'ensemble des sorties des arbres, des prévisions quantiles peuvent être tirées. Ils ont cependant une faiblesse notable pour des prévisions DLR : Un schéma de ce modèle est proposé sur la **Figure 2-2**.



**Figure 2-2.** Schéma de fonctionnement d'un modèle de régression quantile par forêt aléatoire.

Le paramétrage d'un tel modèle est relativement simple, des variations autour des paramètres choisis entraînant des évolutions des caractéristiques statistiques du modèle relativement faibles, contrairement à ce qui est observé pour le Gradient Boosting Regression Tree (GBRT) évoqué ci-après :

- Le nombre de k arbres décisionnels est fixé comme élevé. Normalement, une valeur variant entre 500 et 1000 arbres est suffisante, mais nous avons préféré travailler avec un nombre d'arbres supérieur, ici 2000, en raison du besoin de se focaliser sur les prévisions à bas quantile.
- Le nombre de variables sélectionnées pour chaque arbre. Nous avons ici suivi une règle générale qui est de fixer ce nombre de variables comme égale à la racine carrée du nombre de dimensions des variables d'entrée.
- La taille minimale des feuilles des arbres, paramètre qui joue sur la complexité des arbres. Nous avons testé plusieurs combinaisons, et nous avons pu constater une relativement faible sensibilité du modèle face à ce paramètre. Nous avons alors fixé ce paramètre comme égal à 5.

### 2.3.1.5. Gradient boosting d'arbres aléatoires (GBRT – Gradient Boosting Regression Trees)

Une deuxième méthode ensembliste a été considérée, un Gradient Boosting Regression Trees (GBRT) [109]. Un tel modèle peut avoir un intérêt pour la prédiction du DLR : il est possible d'utiliser des fonctions de perte paramétrables, ce que ne permet pas le modèle QRF proposé.

La régression quantile repose sur un coût des erreurs de prévisions évoluant de manière linéaire avec la magnitude des erreurs. Or, le coût réel pris en compte par les gestionnaires de réseau tendrait plutôt à évoluer de manière quadratique ou exponentielle avec la magnitude de l'erreur. Un GBRT permet alors de prendre en considération de telles fonctions, et il est alors aussi considéré ici.

Contrairement au QRF qui entraîne les modèles d'arbres décisionnels de manière parallèle, sans prendre en considération les performances des différents arbres, un modèle de GBRT va entraîner des arbres

décisionnels de manière itérative, en considérant les performances du modèle précédent en accord avec une fonction perte définie par l'utilisateur. On peut succinctement définir l'algorithme comme suit :

On commence par entraîner un premier modèle de prévision  $F_{0,h}$ . Sa nature importe peu, certains prenant par exemple la valeur moyenne des valeurs observées dans l'échantillon d'apprentissage. Ensuite, on suit le processus itératif suivant, considérant un modèle  $F_{n,h}$  :

- On calcule le gradient associé à l'erreur de prévision du modèle en considérant une fonction perte  $L_{\text{GBRT}}$  :

$$-g(X_{t_i}) = -\frac{\delta L_{\text{GBRT}}(Y_{t+h}, F_{n,h}(X_t))}{\delta F_{n,h}(X_{t_i})} \quad (2-16)$$

- On crée un arbre décisionnel  $h_{n,h}$ , non plus avec les observations  $Y_{t+h}$  comme variables de sortie, mais avec les variables  $-g(X_{t_i})$ .
- On définit un nouveau modèle  $F_{n+1,h}$  comme suit :

$$F_{n+1,h}(X_{t_i}) = F_{n,h}(X_{t_i}) + p_{\text{learning}} \cdot h_{n,h}(X_{t_i}) \quad (2-17)$$

où  $p_{\text{learning}}$  est un paramètre d'apprentissage.

Contrairement au QRF vu précédemment, le GBRT peut être plus sensible au paramétrage dans ses performances. Nous avons utilisé les paramètres suivants :

- Le paramètre d'apprentissage  $p_{\text{learning}}$  a été fixé égal à 0,02.
- Le nombre d'itérations effectuées par le GBRT : là où pour un QRF un nombre d'arbres élevé permet d'améliorer le modèle, ce n'est pas le cas pour le GBRT où un trop grand nombre d'arbres peut amener à faire du surapprentissage, les modèles générés dans les itérations de fin se focalisant sur la prévision du bruit. De manière générale, il est recommandé de fixer ce paramètre par validation croisée, après avoir fixé un paramètre d'apprentissage bas [110]. Celui-ci a été dans notre cas défini de manière arbitraire, après plusieurs avoir testé plusieurs combinaisons de paramètre. Nous avons fixé deux valeurs différentes : 600 itérations pour des prévisions quantiles avec des quantiles compris entre 15% et 85%, et 200 itérations pour des quantiles aux extrémités hors de cet intervalle, un nombre d'arbres supérieurs à 200 entraînant des dégradations pour les prévisions à haut et bas quantiles, mais pas pour les prévisions à quantiles moyens.
- Le nombre de variables sélectionnées aléatoirement pour l'entraînement de chaque arbre est, comme pour le QRF, fixé comme égal à la racine quadratique du nombre de dimension  $d$ . Des variations autour de cette valeur entraînent des modifications pour la performance des modèles peu significatives.
- Le nombre d'observations utilisées pour l'entraînement de chaque arbre : ces observations sont sélectionnées de manière aléatoire, sans possibilité de doublon comme avec un processus de bagging. On a fixé ce paramètre comme égal à 90% du nombre total d'observations.
- Enfin, la complexité des arbres joue un rôle important. On a ici fixé ce paramètre avec la taille maximale de la taille des feuilles des arbres, fixée à 30, et pour tous les quantiles considérés. Il est à noter que des variations pouvaient entraîner des dégradations importantes du modèle, contrairement à ce qu'on a observé pour le QRF. Par exemple, les scores quantiles évaluant les prévisions quantiles allant de 1% à 20% subissaient des augmentations importantes. Ainsi, pour une taille maximale de feuille passant de 30 à 5, ces scores quantiles augmentent de 50% en passant de 20 A à 30 A.

Une méthode automatique pour identifier ces paramètres, comme par exemple l'utilisation de processus d'optimisation bayésienne [111], n'a pas ici été utilisée pour identifier ces paramètres.

Le modèle GBRT présente plusieurs avantages similaires au QRF : il est non-paramétrique, et il est peu sensible au surapprentissage comme nous le verrons plus tard.

Il est souvent considéré car contrairement au QRF, il est peu sensible à des problèmes de biais : pour un nombre de variables important, le QRF serait moins à même de modéliser des relations complexes, en raison de l'entraînement des arbres en parallèle, que le GBRT qui les entraîne de manière itérative. Cela est cependant un problème qui peut être considéré comme peu important pour la prédiction du DLR : la prédiction du DLR est faite avec un nombre de variables relativement réduit, quelques dizaines, et des problèmes de biais auraient un impact limité.

Par rapport aux faiblesses de ce modèle, on fera remarquer que la difficulté à paramétrer le GBRT par rapport au QRF peut le rendre moins attractif. Là où pour un problème de prédiction déterministe, un seul paramétrage est nécessaire, un GBRT nécessite un paramétrage différent pour chaque quantile. L'entraînement est le paramétrage du modèle devient alors très long par rapport à ce qui est nécessaire pour le QRF.

Aussi, comme le QLR et contrairement au QRF, une telle approche présente aussi l'inconvénient de ne pas garantir la cohérence entre les différentes prévisions quantiles, un agencement étant nécessaire après la génération des prévisions pour assurer que  $\hat{Y}_{t+h|t}^{\tau^-} > \hat{Y}_{t+h|t}^{\tau^+}$  avec  $\tau^+ > \tau^-$ .

## 2.3.2. Evaluation des modèles de prédiction

### 2.3.2.1. Indices d'évaluation déterministes

Les études mettant en avant des comparaisons de modèles de prédiction du DLR et leur évaluation sont rares. Dans [48], on compare les capacités de 4 méthodologies différentes à fournir des prévisions ponctuelles avec deux indices d'évaluation de prédiction déterministe différents :

- L'erreur absolue moyenne en pourcentage (MAPE pour *Mean Absolute Percentage Error*) :

$$\text{MAPE} = 100\% \cdot \frac{\sum_{t=1}^n \left| \frac{\hat{Y}_{t+h|t} - Y_{t+h}}{Y_{t+h}} \right|}{n} \quad (2-18)$$

- L'erreur moyenne en pourcentage (MPE pour *Mean Percentage Error*) :

$$\text{MPE} = 100\% \cdot \frac{\sum_{t=1}^n \left| \frac{\hat{Y}_{t+h|t} - Y_{t+h}}{Y_{t+h}} \right|}{n} \quad (2-19)$$

Dans le cas de notre étude, nous évaluons aussi la capacité de nos modèles probabilistes à fournir des prévisions ponctuelles. On considère pour cela la prédiction ponctuelle comme égale à la moyenne de la prédiction probabiliste, la moyenne étant plus régulièrement utilisée que la médiane dans le cas de la prédiction ponctuelle du DLR.

De par le fait que des prévisions à quantile élevé influencent alors cet indice d'évaluation, et que de telles prévisions n'ont en pratique pas d'impact sur l'utilisation des prévisions DLR, on peut considérer que cet indice n'est pas adapté à une évaluation optimale des performances des modèles de prévision du DLR.

En revanche, si on considère l'indice du MAPE, on travaille alors avec un indice qui est déjà régulièrement utilisé dans la littérature. La valeur du MPE est elle peu utilisée. Le fait d'utiliser cet indice du MAPE permet alors de valider la qualité de nos modèles à fournir des prévisions déterministes, en comparaison avec ceux présentés dans la littérature.

### 2.3.2.2. Indices d'évaluation probabilistes

Par la suite, on cherchera à évaluer les performances de nos modèles probabilistes. Aucune étude dans la littérature ne s'intéresse à la fois à l'évaluation de prévisions du DLR probabiliste à l'aide indices statistiques d'évaluation, à l'exception de [81], où le Continuous Ranked Probability Score est utilisé, et ce encore pour évaluer des prévisions météorologiques intermédiaires et non la prévision du DLR finale. On doit donc définir dans un premier temps une sélection d'indices à utiliser.

En premier lieu, on doit rappeler que trois critères [112] sont associés à la performance de modèles probabilistes :

- La **fiabilité**, c'est la capacité du modèle à associer des probabilités justes à des phénomènes prédits. Pour des quantiles sélectionnés, elle est évaluée en calculant la fréquence moyenne des situations où les observations sont supérieures aux prévisions. Plus ces fréquences sont proches des niveaux de probabilité donnés, plus les prévisions sont fiables.
- La **finesse**, elle, est la capacité du modèle à fournir des densités de probabilité à la dispersion plus ou moins importantes, des intervalles de prévisions associés à des intervalles de probabilité étant plus ou moins fins et une prévision parfaite selon cet indice étant une fonction de Dirac. Ici, on l'évaluera comme la taille moyenne des intervalles de prévision 3%-97%.
- La **résolution**, correspondant à la variabilité des densités de probabilité fournies par un modèle en fonction des données d'entrée. Dans le cas d'une prévision parfaitement fiable, la fiabilité et la finesse sont équivalents [113]. Pour cette raison, seules la finesse et la fiabilité sont régulièrement considérées [48].

Comme pour des prévisions déterministes, il peut être souhaité de pouvoir évaluer les modèles à partir d'un seul score, évaluant les trois caractéristiques en même temps. Il existe alors des indices d'évaluation, prenant en compte l'ensemble des caractéristiques des prévisions. Parmi les plus connus, on pourrait citer le score quadratique, le score sphérique et le score logarithmique [114].

Dans une compétition récente, la Global Energy Forecasting Competition [115], où des prévisions probabilistes de consommation, de production éolienne et de production solaire ont été évaluées, l'indice du Continuous Ranked Probability Score (CRPS) [116] était utilisé, sous la forme d'une somme de 99 scores quantiles associés aux percentiles.

Dans notre travail, nous avons considéré deux indices d'évaluation:

- Le **Continuous Ranked Probability Score (CRPS)** [117], qui est une mesure de la distance entre la densité de probabilité cumulée et l'observation. Dans le cas d'une densité de probabilité qui est une fonction de Dirac, le CRPS devient équivalent à l'erreur absolue. Il est défini comme l'intégrale du score de Brier [118] pour l'ensemble des valeurs seuils définies sur  $R$ :

$$\text{CRPS}(\hat{f}_{t+h|t}, Y_{t+h}) = \frac{1}{n} \int_{-\infty}^{\infty} (\hat{F}_{t+h|t}(x) - 1_{x \geq Y_{t+h}})^2 dx \quad (2-20)$$

$$\hat{F}_{t+h|t}(x) = \int_{-\infty}^x \hat{f}_{t+h|t}(x) dx \quad (2-21)$$

Le CRPS peut aussi  tre  crit fonction du score quantile, qui est inspir  de la fonction Pinball pr cedemment pr sent e.

$$\text{CRPS}(\hat{f}_{t+h|t}, Y_{t+h}) = \int_0^1 \text{QS}_\tau(\hat{F}_{t+h|t}^{-1}(\tau), Y_{t+h}) d\tau \quad (2-22)$$

$$\text{QS}_\tau(\hat{Y}_{t+h|t}^\tau, Y_{t+h}) = \begin{cases} 2 \cdot (1 - \tau) \cdot (\hat{Y}_{t+h|t}^\tau - Y_{t+h}) & \text{si } Y_{t+h} < \hat{Y}_{t+h|t}^\tau \\ 2 \cdot \tau \cdot (Y_{t+h} - \hat{Y}_{t+h|t}^\tau) & \text{si } Y_{t+h} \geq \hat{Y}_{t+h|t}^\tau \end{cases} \quad (2-23)$$

Notre choix du CRPS pour  valuer les pr visions DLR est motiv  par plusieurs raisons.

En plus d' tre r guli rement utilis  pour des  valuations de pr visions faites dans le domaine de l' nergie, cet indice est int ressant car il d pend des valeurs des densit s de pr visions cumul es  $\hat{F}_{t+h|t}$  et non des densit s de probabilit   $\hat{f}_{t+h|t}$ , ces derni res devant  tre estim es   partir de pr visions quantiles avec des mod les qui fournissent directement de telles pr visions.

Avec des indices d' valuation requ rant la valeur de  $\hat{f}_{t+h|t}$  comme par exemple le score logarithmique, il serait difficile d' valuer des mod les comme des r gressions lin aires quantiles, pour lesquels il peut  tre impossible d'obtenir des valeurs de  $\hat{f}_{t+h|t}$ . En effet, il arrive parfois que des pr visions pour un quantile donn  soient sup rieures   des pr visions pour un autre quantile, cet autre quantile  tant cependant sup rieur. M me si on traite les valeurs des pr visions quantiles pour  viter ce probl me, il est difficile de consid rer les valeurs de  $\hat{f}_{t+h|t}$  comme correctes.

Aussi, on  voquera d s maintenant les r sultats pr sent s dans le chapitre 5, dans la section 5.7.3, qui montrent une forte corr lation entre la valeur financi re des pr visions DLR et la valeur du CRPS associ e   ces pr visions ( $\approx -0.9$ ), dans le cas d'utilisation de strat gies d'optimisation neutre au risque. Cette corr lation observ e nous permet de l gitimer le choix de l'indice du CRPS pour  valuer des pr visions probabilistes du DLR.

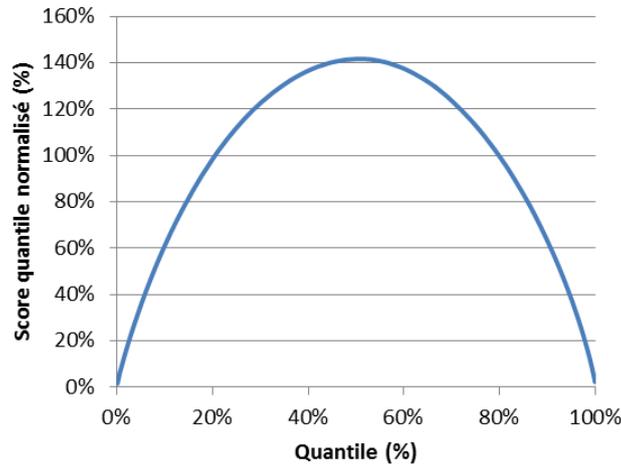
- Le **score quantile moyen (QSmoy)**, qui n'est pas la moyenne des scores quantiles pour l'ensemble des quantiles comme avec le calcul du CRPS, mais la moyenne des scores quantiles pour des intervalles de quantiles donn s  $[\tau_1, \tau_2]$ :

$$\text{QSmoy}(\tau_1, \tau_2) = \int_{\tau_1}^{\tau_2} \text{QS}_\tau(\hat{F}_{t+h|t}^{-1}(\tau), Y_{t+h}) d\tau \quad (2-24)$$

Cet indice a pour objectif de permettre d' valuer seulement les parties basses de distribution, l  o  l'indice du CRPS prendra aussi en compte la qualit  des pr visions   haut quantile, peu utiles dans le cas du DLR.

Ces indices peuvent poser probl me, dans le sens o  il ne donne pas un m me poids   l'ensemble des pr visions quantiles. Pour illustrer ce point, on repr sente sur la **Figure 2-3** ci-dessous l' volution des

valeurs des scores quantiles en fonction des quantiles sélectionnés, ce pour un ensemble de prévisions obtenues avec un des modèles de prévision présenté dans le chapitre 3.



**Figure 2-3.** Evolutions des valeurs des scores quantiles en fonction des quantiles sélectionnés. Les prévisions utilisées sont issues de modèles présentés dans le chapitre 3.

Ces variations entre les valeurs des différents scores quantiles font par exemple que le CRPS tend à ne pas considérer la qualité des prévisions associées aux queues des distributions, la somme des scores quantiles allant de 0% à 5% ne représentant par exemple ici que 1% de la valeur du CRPS.

Dans [119], ce problème est abordé, et il est proposé d'ajouter des pondérations aux scores quantiles de manière à mettre en avant des parties des densités de distribution différentes.

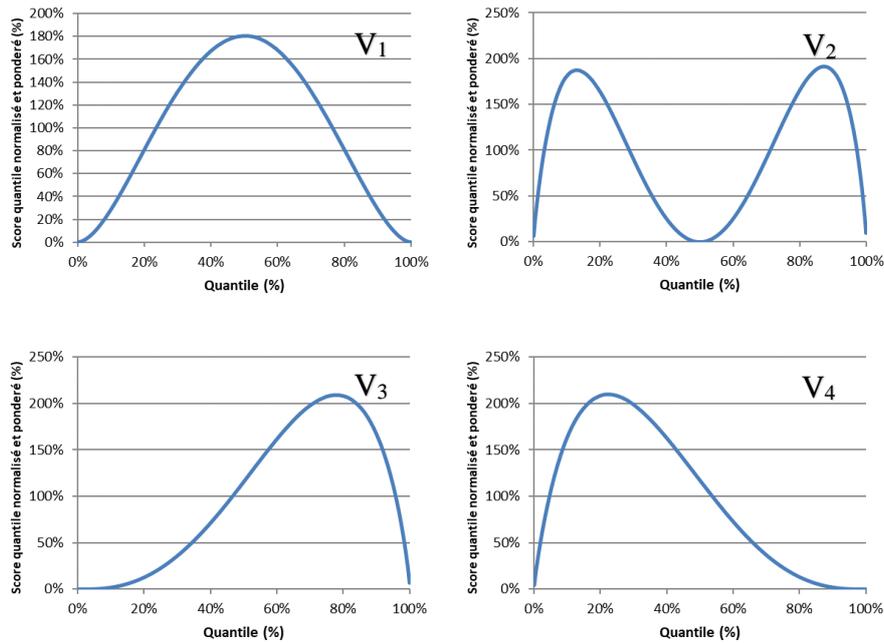
$$\text{CRPS\_pond} = \int_0^1 \text{QS}_\alpha(\hat{F}_{t+h|t}^{-1}(\alpha), Y_{t+h}) \cdot v(\alpha) d\alpha \quad (2-25)$$

Où la fonction  $v$  est définie de manière différente, en fonction de la partie de distribution sur laquelle on souhaite concentrer l'évaluation du modèle de prévision. Les différentes fonctions  $v$  sont reprises sur le **Tableau 2-4**.

**Tableau 2-4.** Forme des fonctions de pondération utilisées pour créer des indices de scoring donnant plus de poids à différentes parties de distribution.

Forme de la fonction $v$	Partie de la distribution mise en avant
$v_0(\alpha) = 1$	Uniforme
$v_1(\alpha) = \alpha \cdot (1 - \alpha)$	Partie centrale
$v_2(\alpha) = (2\alpha - 1)^2$	Queues de distribution
$v_3(\alpha) = \alpha^2$	Queue haute
$v_4(\alpha) = (1 - \alpha)^2$	Queue basse

Sur la **Figure 2-4**, on trace les valeurs des scores quantiles pondérés avec les fonction  $v$ , par rapport aux scorings modifiés.



**Figure 2-4.** Evolution des scores quantiles pondérés, normalisés par rapport aux valeurs du score global obtenu par le calcul de la moyenne des scores quantiles pondérés.

La modification proposée avec la fonction  $v_4$ , permettant de donner un poids plus important pour la partie basse de la distribution, généralement plus utile pour les prévisions DLR, pourrait être intéressante.

Cependant, si on observe le ratio entre les différents scores quantiles pour les quantiles bas, on constate que l'utilisation d'une telle fonction par rapport à la fonction  $v_0$  apporte des bénéfices limités. Ainsi, les ratios entre les scores quantile à 20% et le score quantile à 1%, pondérés avec  $v_0$  et  $v_4$ , n'évolue que de 10 à 7. C'est une amélioration, mais nous ne la jugeons pas ici comme suffisamment importante pour justifier le fait d'utiliser dans nos travaux un indice d'évaluation modifié par rapport à un indice d'évaluation plus standard.

### 2.3.2.3. Problématique de limitation minimale du DLR

Les différents indices évoqués permettent d'évaluer les sorties des modèles de prévision, mais il est à souligner que celles-ci peuvent prendre des valeurs absurdes, car trop faibles ou trop élevées. Pour illustrer cela, on pourrait prendre l'exemple d'une éolienne pour laquelle une prévision estime le niveau de probabilité associé à une puissance générée négative. Dans le cas du DLR, on trouve une situation similaire, des modèles pouvant prévoir des valeurs trop basses par rapport à ce qui est attendu, mais restant cependant utiles dans leur capacité à prévoir des situations dangereuses. Il est alors nécessaire de transformer les prévisions fournies, en les limitant entre des valeurs maximales et minimales.

Deux approches peuvent être choisies :

- On considère que la valeur de DLR utilisée en pratique ne peut être inférieure au SLR, et dans ce cas on fixe un minimum pour les prévisions égales au SLR.
- On considère une valeur minimale théorique pour le RTL, égale par exemple à une valeur minimale observée sur une saison, moins une marge de sécurité.

Dans ce chapitre, nous ne considérerons pas la définition de ce minimum pour la modification de nos prévisions, et ces considérations sur l'évaluation des modèles seront discutées à nouveau dans la section 5.7.3.

### 2.3.3. Variables explicatives utilisées

#### 2.3.3.1. Variables initiales

Les prévisions sont faites à partir de variables d'entrée, et il est nécessaire de définir les variables qui seront utilisées pour l'entraînement du modèle. On peut ici reprendre les variables proposées dans [48], le cas d'étude étant le même que le nôtre. Les auteurs considèrent alors, pour une prévision faite à un instant  $t$  pour un instant  $t+h$ , un total de 34 variables :

- Les valeurs observées aux instant  $t$ ,  $t-15mn$ ,  $t-30mn$ ,  $t-45mn$ ,  $t-60mn$  et  $t-24h$  de RTLRL observées sur une station donnée.
- Les valeurs observées aux instants évoqués ci-dessus, pour les 4 paramètres météorologiques (la vitesse du vent (m/s), la direction du vent (rad), l'irradiation solaire globale ( $W/m^2$ ) et la température ambiante (K)).
- Des prévisions météorologiques pour la localisation de la station, et qui sont obtenues à l'aide d'un downscaling statistique et de prévisions fournies par ECMWF (rappel : les quatre paramètres prévus sont les vitesses de vent zonale et méridionale à 10m (m/s), l'irradiation solaire globale ( $W/m^2$ ) et la température ambiante ( $^{\circ}C$ )).

Pour ces 4 dernières variables, les auteurs proposent d'utiliser deux interpolations, une temporelle et une spatiale. L'interpolation temporelle est simple : les prévisions sont générées toutes les 12 heures seulement pour des horizons multiples de 3 heures. Afin de pouvoir travailler sur des horizons ne respectant pas ce critère, des interpolations linéaires sont faites entre les prévisions temporelles obtenues pour deux horizons différents.

Pour l'interpolation spatiale, des données de réanalyse sont utilisées (on considère les prévisions faites à un instant  $t$  pour un même instant  $t$ ), ce pour générer un modèle linéaire liant les observations faites aux stations aux 4 valeurs de réanalyse fournies pour les positions encadrant la station météorologique considérée.

Par la suite, l'ensemble des 4 prévisions météorologiques pour l'instant  $t+h$  utilisées sont considérées comme entrées du modèle linéaire de downscaling statistique, et une prévision modifiée est obtenue en sortie du modèle.

Le set de variables que l'on se propose d'utiliser, composé lui de 27 variables, est différent.

Tout d'abord, nous avons souhaité travailler sur des prévisions en se focalisant sur des horizons à court-terme (>6 heures). Pour cette raison, nous avons considéré avoir moins besoin de variables observées, et nous n'en avons considéré que deux, l'observation du RTLRL à l'instant où la prévision est faite, et la valeur moyenne de trois observations RTLRL, faites sur les trois jours qui précèdent le moment de la prévision à la même heure que l'heure pour laquelle la prévision est faite.

Nous avons aussi considéré les prévisions météorologiques, pour 5 paramètres : les 4 mêmes paramètres que ceux utilisés dans [48], et un cinquième correspondant à des prévisions RTLRL, obtenues par

l'utilisation du modèle physique associé au calcul de l'ampacité vu dans le chapitre 1, avec pour entrées les 4 prévisions météorologiques évoquées :

$$\widehat{RTL}_{t+h|t}^{NWP} = f_{\text{physique}}(\widehat{U}_{t+h|t}^{NWP}, \widehat{V}_{t+h|t}^{NWP}, \widehat{T}_{t+h|t}^{NWP}, \widehat{S}_{t+h|t}^{NWP}) \quad (2-26)$$

Ces prévisions ont été considérées à la fois pour les 4 positions les plus proches de la station météorologique considérée, et pour la position de la station avec le même type de downscaling statistique évoqué. Pour les 4 prévisions encadrant la position de la station, on note les positions des prévisions comme suit :

- La position 1 correspond à la prévision faite au sud-ouest de la position de la station.
- La position 2 correspond à la prévision faite au sud-est de la position de la station.
- La position 3 correspond à la prévision faite au nord-ouest de la position de la station.
- La position 4 correspond à la prévision faite au nord-est de la position de la station.

La corrélation entre ces variables est importante, mais cela n'était pas nécessairement problématique pour l'entraînement des modèles : soit une part importante de ces variables étaient supprimée, en raison des réductions du nombre de variables faites pour plusieurs modèles, soit celles-ci n'avaient pas d'influence pour certains modèles peu sensibles au surapprentissage comme le QRF.

Sur le **Tableau 2-5**, on reprend les 27 variables évoquées ainsi que la nomenclature utilisée pour les décrire.

**Tableau 2-5.** Récapitulatif des 27 variables initialement choisies pour entraîner les modèles de prévision.

RTLRL_0_ob	Observation RTLRL à une station donnée au moment où la prévision est faite. (A)
RTLRL_m_ob	Observation RTLRL moyenne à une station donnée, pour les trois jours précédents à la même heure que celle pour laquelle la prévision est faite. (A)
U_t+h_1	Prévision de la composante est-ouest du vent à 10m pour la position 1, fournie à l'instant de la prévision pour l'horizon de la prévision. (m.s <sup>-1</sup> )
U_t+h_2	Prévision de la composante est-ouest du vent à 10m pour la position 2, fournie à l'instant de la prévision pour l'horizon de la prévision. (m.s <sup>-1</sup> )
U_t+h_3	Prévision de la composante est-ouest du vent à 10m pour la position 3, fournie à l'instant de la prévision pour l'horizon de la prévision. (m.s <sup>-1</sup> )
U_t+h_4	Prévision de la composante est-ouest du vent à 10m pour la position 4, fournie à l'instant de la prévision pour l'horizon de la prévision. (m.s <sup>-1</sup> )
V_t+h_1	Prévision de la composante sud-nord du vent à 10m pour la position 1, fournie à l'instant de la prévision pour l'horizon de la prévision. (m.s <sup>-1</sup> )
V_t+h_2	Prévision de la composante sud-nord du vent à 10m pour la position 2, fournie à l'instant de la prévision pour l'horizon de la prévision. (m.s <sup>-1</sup> )
V_t+h_3	Prévision de la composante sud-nord du vent à 10m pour la position 3, fournie à l'instant de la prévision pour l'horizon de la prévision. (m.s <sup>-1</sup> )
V_t+h_4	Prévision de la composante sud-nord du vent à 10m pour la position 4, fournie à l'instant de la prévision pour l'horizon de la prévision. (m.s <sup>-1</sup> )
T_t+h_1	Prévision de la température ambiante pour la position 1, fournie à l'instant de la prévision pour l'horizon de la prévision. (K)
T_t+h_2	Prévision de la température ambiante pour la position 2, fournie à l'instant de la prévision pour l'horizon de la prévision. (K)
T_t+h_3	Prévision de la température ambiante pour la position 3, fournie à l'instant de la prévision pour l'horizon de la prévision. (K)
T_t+h_4	Prévision de la température ambiante pour la position 4, fournie à l'instant de la prévision pour l'horizon de la prévision. (K)
S_t+h_1	Prévision de l'irradiation solaire globale pour la position 1, fournie à l'instant de la prévision pour l'horizon de la prévision. (W.m <sup>-2</sup> )
S_t+h_2	Prévision de l'irradiation solaire globale pour la position 2, fournie à l'instant de la prévision pour l'horizon de la prévision. (W.m <sup>-2</sup> )
S_t+h_3	Prévision de l'irradiation solaire globale pour la position 3, fournie à l'instant de la prévision pour l'horizon de la prévision. (W.m <sup>-2</sup> )
S_t+h_4	Prévision de l'irradiation solaire globale pour la position 4, fournie à l'instant de la prévision pour l'horizon de la prévision. (W.m <sup>-2</sup> )
RTLRL_t+h_1	Prévision de la valeur de la RTLRL pour la position 1, fournie à l'instant de la prévision pour l'horizon de la prévision. La RTLRL est calculée comme $f_{\text{physique}}(U_{t+h_1}, V_{t+h_1}, T_{t+h_1}, S_{t+h_1})$ (A)
RTLRL_t+h_2	Prévision de la valeur de la RTLRL pour la position 2, fournie à l'instant de la prévision pour l'horizon de la prévision. La RTLRL est calculée comme $f_{\text{physique}}(U_{t+h_2}, V_{t+h_2}, T_{t+h_2}, S_{t+h_2})$ (A)
RTLRL_t+h_3	Prévision de la valeur de la RTLRL pour la position 3, fournie à l'instant de la prévision pour l'horizon de la prévision. La RTLRL est calculée comme $f_{\text{physique}}(U_{t+h_3}, V_{t+h_3}, T_{t+h_3}, S_{t+h_3})$ (A)
RTLRL_t+h_4	Prévision de la valeur de la RTLRL pour la position 4, fournie à l'instant de la prévision pour l'horizon de la prévision. La RTLRL est calculée comme $f_{\text{physique}}(U_{t+h_4}, V_{t+h_4}, T_{t+h_4}, S_{t+h_4})$ (A)
U_t+h_SD	Prévision de la composante est-ouest du vent pour la position de la station météorologique, fournie à l'instant de la prévision pour l'horizon de la prévision. La variable est calculée à partir d'une opération de statistical downscaling et de (U_t+h_1, U_t+h_2, U_t+h_3, U_t+h_4) (m.s <sup>-1</sup> )
V_t+h_SD	Prévision de la composante sud-nord du vent pour la position de la station météorologique, fournie à l'instant de la prévision pour l'horizon de la prévision. La variable est calculée à partir d'une opération de statistical downscaling et de (V_t+h_1, V_t+h_2, V_t+h_3, V_t+h_4) (m.s <sup>-1</sup> )
T_t+h_SD	Prévision de la température ambiante pour la position de la station météorologique, fournie à l'instant de la prévision pour l'horizon de la prévision. La variable est calculée à partir d'une opération de statistical downscaling et de (T_t+h_1, T_t+h_2, T_t+h_3, T_t+h_4) (K)
S_t+h_SD	Prévision de l'irradiation solaire globale pour la position de la station météorologique, fournie à l'instant de la prévision pour l'horizon de la prévision. La variable est calculée à partir d'une opération de statistical downscaling et de (S_t+h_1, S_t+h_2, S_t+h_3, S_t+h_4) (W.m <sup>-2</sup> )
RTLRL_t+h_SD	Prévision de la valeur de la RTLRL pour la position de la station météorologique, fournie à l'instant de la prévision pour l'horizon de la prévision. La RTLRL est calculée avec (U_t+h_SD, V_t+h_SD, T_t+h_SD, S_t+h_SD) (A)

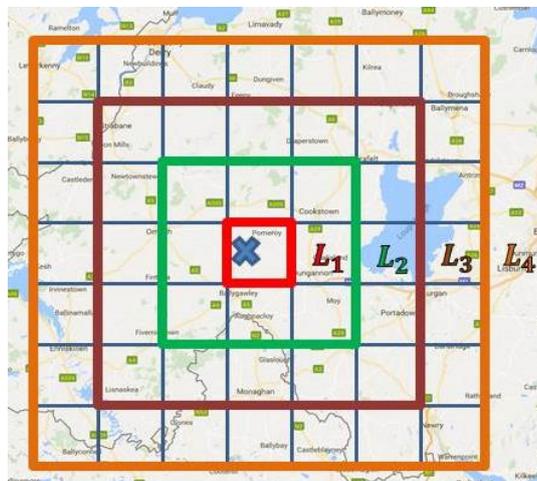
### 2.3.3.2. Discussion sur l'ajout de variables liées aux risques d'erreurs de prévisions

Plusieurs approches associées aux prévisions du DLR tiennent d'une certaine manière compte des risques d'erreur de prévision, associées aux prévisions météorologiques considérées. On peut ici considérer par exemple :

- L'étude [73], dans laquelle des prévisions météorologiques ensemblistes sont considérées pour générer les prévisions probabilistes des paramètres météorologiques.
- L'étude [89], où ce sont les erreurs historiques des prévisions qui sont utilisées pour obtenir une information sur les écarts-types associés à des prévisions probabilistes de paramètres météorologiques.

Nous avons investigué l'intérêt d'intégrer dans notre modèle des variables tenant compte de tels paramètres. Pour ce faire, nous avons considéré un ajout de variables spatiales. Une première approche aurait pu être d'utiliser des observations météorologiques de stations à proximité, comme proposé dans [81] pour le cas du DLR.

Or, en raison des horizons de prévision considérés, nous avons préféré travailler avec des données générées à partir de prévisions météorologiques. Nous avons alors repris une approche proposée dans [120]. Dans cet article, les auteurs proposent de considérer l'information qui peut être tirée d'une grille de prévisions météorologiques (**Figure 2-5**).



**Figure 2-5.** Représentation d'une maille de prévisions météorologiques encadrant une station météorologique (croix bleue).

Cela est fait au moyen de la génération de deux catégories de variables :

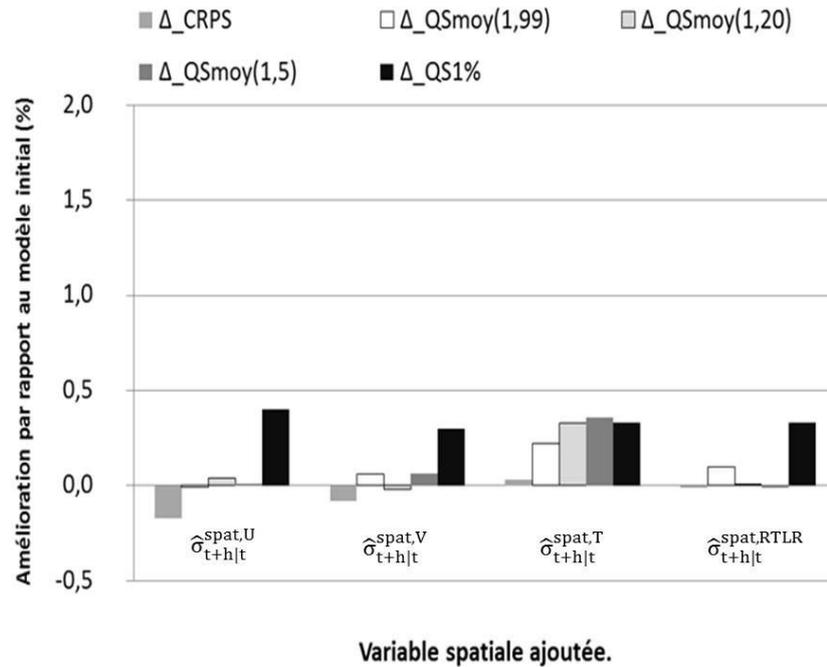
- Des variables issues d'une analyse par composante principale faite sur 169 variables d'une grille ayant 13 éléments par côté, telle que 90% de la variance soit expliquée.
- L'écart-type et la valeur moyenne des prévisions sur la grille de  $N_p$  prévisions considérées.

$$\hat{\sigma}_{t+h|t}^{\text{spat,NWP}} = \sqrt{\frac{\sum_{i=1}^{N_p} (x_{t+h|t}^{\text{NWP},i} - \bar{x}_{t+h|t}^{\text{NWP}})^2}{N_p - 1}} \quad (2-27)$$

Ensuite, une évaluation de différents modèles est faite, et les auteurs observent les améliorations possibles d'indices d'évaluation (CRPS, MAPE) selon que de nouvelles variables sont introduites ou

non. Nous avons utilisé une approche similaire à celle de [120], considérant des modèles QRF initiaux, entraînés pour des horizons allant de 24 heures à 48 heures, avec des fenêtres glissantes d'un mois et pour les 8 stations météorologiques considérées.

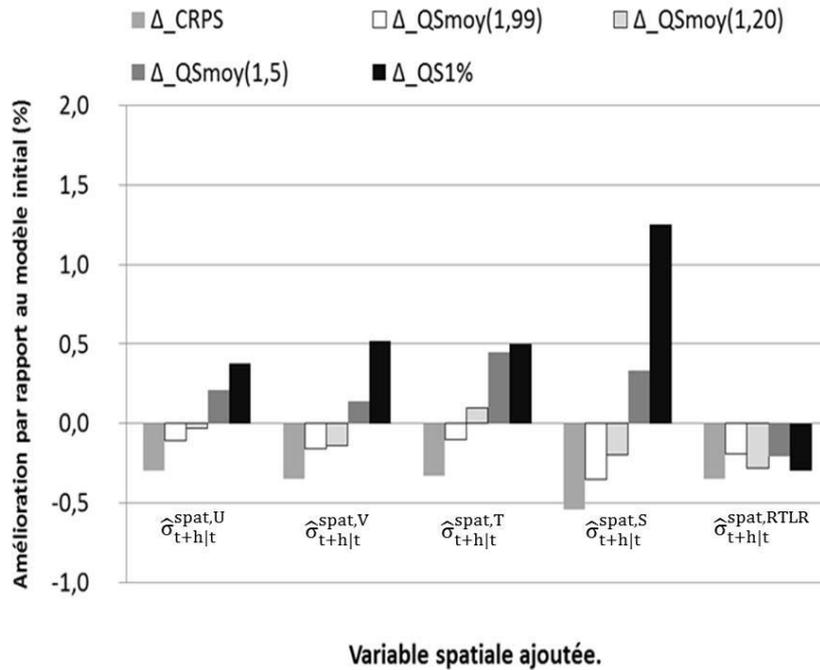
Pour l'ensemble de ces prévisions, la **Figure 2-6** montre l'amélioration relative des prévisions en fonction de la variable ajoutée, sans considérer l'irradiation solaire nulle pendant la nuit. Contrairement aux résultats présentés dans [120] où des améliorations relatives du CRPS et du MAPE de l'ordre de 10% étaient obtenues, les résultats observés ont été relativement médiocres, ce avec des variables ajoutées individuellement, ou pour l'ensemble des combinaisons possibles de ces 4 variables.



**Figure 2-6.** Amélioration relative des prévisions faites à midi, en fonction de la variable ajoutée, moyennée sur les 8 stations étudiées pour des horizons de prévision allant de 24 heures à 48 heures.

Par la suite, nous avons fait une étude similaire (**Figure 2-7**), mais en ne considérant que les prévisions faites pour des horaires entre 7h00 et 17h00, afin de pouvoir ajouter l'effet d'une variable issue des prévisions d'irradiation solaire. On peut alors noter que la variable issue de la prévision de l'irradiation solaire permet une amélioration supérieure à ce qui était observé pour les autres variables, pour les prévisions à très bas quantile.

Cependant, les améliorations relatives observées étant faibles, nous n'avons pas plus poussé l'investigation relative à l'intérêt de ce type de variable, que ce soit des variables spatiales, temporelles ou encore associées aux prévisions ensemblistes, et nous n'avons pas ajouté ces catégories de variables aux entrées de nos modèles.



**Figure 2-7.** Amélioration relative des prévisions faites à midi, en fonction de la variable ajoutée, moyennée sur les 8 stations étudiées pour des horizons de prévision allant de 24 heures à 31 heures, et de 41 heures à 48 heures (seules les prévisions en journée, de 7h00 à 17h00, sont considérées).

### 2.3.4. Classement des variables

Les différents modèles présentés peuvent avoir une sensibilité plus ou moins importante au nombre de variables. Dans le cas d'un nombre de variables élevé, on parle de surapprentissage (*overfitting* en anglais), les modèles de prévision entraînés avec un échantillon d'apprentissage pouvant devenir non utilisables sur de nouveaux échantillons.

De plus, et comme nous le verrons ici, ce type de phénomène peut apparaître différemment fonction de l'utilisation des modèles pour fournir des prévisions déterministes ou à bas quantile.

Nous présentons dans cette section deux méthodes de traitement des données d'entrée qui ont été utilisées, une première basée sur l'utilisation de variables non traitées et classées suivant un algorithme glouton, et une deuxième basée sur l'utilisation d'une Analyse par Composante Principale en amont de l'entraînement des modèles suivie de la sélection d'un nombre limité de variables transformées. Par la suite, nous présentons les résultats associés à l'étude de l'influence du nombre de variables sélectionnées sur les qualités des différents modèles proposés, ce pour différents indices statistiques d'évaluation.

#### 2.3.4.1. Algorithme glouton avec critère d'information mutuelle.

On s'intéresse dans un premier temps à un entraînement des modèles avec un nombre de variables limité. La sélection des variables se fait selon un algorithme glouton (*greedy algorithm*) : on sélectionne une première variable fortement liée à la sortie, et on ajoute ensuite de manière incrémentale de nouvelles variables pour observer l'effet obtenu sur la performance du modèle [121].

Pour sélectionner la première variable, plutôt que d'utiliser le coefficient de corrélation pour mesurer la dépendance entre la sortie  $Y$  et la variable considérée  $X_1$ , on s'inspire d'une approche proposée dans [104], où le coefficient d'information mutuelle (MI) est utilisé :

$$MI(X_1, Y) = \sum_{x_1, y} P(x_1, y) * \log\left(\frac{P(x_1, y)}{P(x_1) * P(y)}\right) \quad (2-28)$$

Contrairement au coefficient de corrélation qui vérifie s'il existe une relation linéaire entre deux variables, le critère d'information mutuelle est en mesure de repérer des relations plus générales. Il est à noter que dans le cas discret, et contrairement au coefficient de corrélation de Pearson, le critère d'information mutuelle peut être inefficace si les données utilisées prennent un nombre de valeurs trop important. On pourrait illustrer cela en disant que si on a des valeurs d'irradiation solaire ayant chacune une valeur différente, alors le coefficient d'information mutuelle sera incapable de repérer des relations potentielles avec une autre variable, tandis que ce ne serait pas le cas si ces valeurs étaient dégradées de manière à n'envisager qu'un nombre de valeurs possibles limité.

Il est alors nécessaire de traiter les données utilisées, et de les classer par cluster, de manière à ce qu'elles n'aient qu'un nombre de valeurs limitées, chaque cluster ayant une valeur associée. Cela est fait en associant les valeurs à des intervalles de même taille, représentant les valeurs possibles entre la valeur minimale et la valeur maximale observées. Ici, 10 intervalles sont considérés.

On sélectionne ensuite une deuxième variable, en considérant encore l'information mutuelle entre la sortie et la nouvelle variable, mais en ajoutant aussi un critère de pénalité par rapport à la relation entre la variable précédemment sélectionnée et la nouvelle variable. Cette nouvelle variable  $X_2$  est donc sélectionnée de manière à maximiser la fonction  $L_1$  :

$$L_1(X_2) = MI(X_2, Y) - \lambda * MI(X_2, X_1) \quad (2-29)$$

Par la suite, ce procédé est à nouveau utilisé pour la sélection d'une  $k^{\circ}$  variable suivante avec la minimisation de la fonction  $L_k$  :

$$L_k(X_k) = MI(X_k, Y) - \lambda * \sum_{j=1}^{k-1} MI(X_k, X_j) \quad (2-30)$$

Pour différentes valeurs de  $\lambda$ , on montre sur le **Tableau 2-6** un exemple de l'ordre des variables sélectionnées par l'algorithme, dans le cas de la station 1 et ce pour des prévisions faites tous les jours à midi pour un horizon de 24 heures. Le tableau se lit ainsi : pour une valeur de  $\lambda$  donnée, on fournit l'ordre  $k$  de la sélection de chaque variable, la variable associée à 1 étant la première variable sélectionnée par l'algorithme.

**Tableau 2-6.** Ordre des variables sélectionnés par l'algorithme glouton, pour des prévisions faites avec pour un horizon de 24 heures pour la station 1. Les modèles sont entraînés pour être utilisés tous les jours à midi.

	$\lambda$	0	0,8	2	5	10
<b>Variables</b>	<b>RTLRL_0_ob</b>	14	3	4	3	3
	<b>RTLRL_m_ob</b>	27	5	5	5	5
	<b>U_t+h_1</b>	8	9	10	10	10
	<b>U_t+h_2</b>	9	16	16	16	16
	<b>U_t+h_3</b>	5	2	3	21	21
	<b>U_t+h_4</b>	7	21	21	4	4
	<b>V_t+h_1</b>	10	24	24	24	24
	<b>V_t+h_2</b>	20	20	20	20	20
	<b>V_t+h_3</b>	11	7	7	7	7
	<b>V_t+h_4</b>	12	25	25	25	25
	<b>T_t+h_1</b>	13	22	22	23	23
	<b>T_t+h_2</b>	21	4	2	2	2
	<b>T_t+h_3</b>	17	18	12	17	17
	<b>T_t+h_4</b>	18	12	19	12	12
	<b>S_t+h_1</b>	22	14	9	14	14
	<b>S_t+h_2</b>	24	10	14	9	8
	<b>S_t+h_3</b>	25	23	23	22	22
	<b>S_t+h_4</b>	23	19	17	19	19
	<b>RTLRL_t+h_1</b>	1	1	1	1	1
	<b>RTLRL_t+h_2</b>	2	15	15	15	15
	<b>RTLRL_t+h_3</b>	3	17	18	18	18
	<b>RTLRL_t+h_4</b>	4	11	11	11	11
	<b>U_t+h_SD</b>	19	13	13	13	13
	<b>V_t+h_SD</b>	16	27	27	27	27
	<b>T_t+h_SD</b>	15	26	26	26	26
	<b>S_t+h_SD</b>	26	6	6	6	6
	<b>RTLRL_t+h_SD</b>	6	8	8	8	9

Bien que ce tableau ne soit que l'illustration d'une sélection de variables dans un cas particuliers, quelques résultats qui ont été observés de manière générale peuvent être commentés.

Tout d'abord, nous avons souligné que cette méthode permettait d'éviter la sélection de variables corrélées entre elles, et on constate en effet que pour une valeur de  $\lambda$  égale à 0,8, il est nécessaire d'atteindre la 9<sup>o</sup> variable sélectionnée pour retrouver deux prévisions d'une même variable faites à deux positions différentes ( $U_{t+h_3}$  et  $U_{t+h_1}$ ).

Ensuite, on constate que la variable la plus explicative est une variable construite à partir des prévisions météorologiques, ici la variable associée à la prévision du DLR à la position 1, créée à l'aide du modèle physique et des prévisions météorologiques, et la nécessité de l'utilisation du modèle physique de l'ampacité d'une ligne pour générer des variables de modèles de prévision DLR apparaît alors claire.

Enfin, avec  $\lambda = 0,8$ , on soulignera le fait que la prévision de l'irradiation solaire globale apparaît comme significative pour la performance des modèles, la variable étant sélectionnée en 6<sup>e</sup> position devant une valeur de prévision de vitesse de vent sud-nord. Même si les prévisions sont faites pour midi, il est notable de noter que cette variable apparaît comme apportant une information plus importante que la prévision de la vitesse du vent sud-nord, ce malgré la faible importance du terme d'échauffement dû à l'irradiation solaire devant le terme de refroidissement par convection.

### 2.3.4.2. Analyse par Composante principale.

L'Analyse par Composante Principale [122] (PCA) est une méthode qui vise à faire un changement de base pour les données considérées de manière à réduire les corrélations entre les différentes variables. Nous avons souhaité utiliser cet algorithme pour obtenir un set de variables à taille limitée, donc adapté à des modèles comme le KDE, conservant cependant une capacité plus importante à expliquer des phénomènes que pour un même nombre de variables non traitées.

L'algorithme peut être décrit comme ci-dessous :

- Dans un premier temps, les variables des échantillons d'entraînement et de test sont normalisées en utilisant les valeurs moyennes  $\bar{X}^{k \text{ train}}$  pour l'ensemble d'entraînement considéré et l'écart-type  $\sigma_{X^{k \text{ train}}}$ .

$$X_t^{k, \text{normalised}} = \frac{X_t^k - \bar{X}^{k \text{ train}}}{\sigma_{X^{k \text{ train}}}} \quad (2-31)$$

- La matrice de covariance  $C$  pour l'échantillon d'entraînement est calculée, comme la matrice des données multipliée par sa transposée. Le résultat est une matrice carrée, réelle et symétrique de taille  $d \times d$ , où  $d$  est le nombre de dimensions.
- En raison des propriétés de la matrice considérée et le théorème spectral, la matrice  $C$  est diagonalisable dans une base orthonormée. Un ensemble de valeurs propres réelles et de vecteurs propres peut alors être obtenu.
- Les différents vecteurs propres peuvent être classés dans un ordre croissant, en fonction de leurs valeurs propres, le premier étant le vecteur sur lequel la projection des données aura la variance la plus importante.
- Une projection pour les ensembles d'entraînement et de test sur la base obtenue est faite, et un nombre de variables limité est sélectionné de manière à conserver une part importante de la variance des données d'entrée.

### 2.3.4.3. Echantillons d'entraînement et de test pour le paramétrage

Comme cela est montré dans [123] pour le cas du MDNN, des échantillons pour entraîner les modèles et définir leurs paramètres doivent être générés par validation croisée. Dans le cas du DLR et dans le cadre de cette thèse, cela est difficile car il n'y a actuellement pas de fonction objectif standard définie pour ce type de prévision. En effet, là où on sait que des producteurs d'énergie renouvelables chercheront la plupart du temps à évaluer dans leur ensemble les densités de probabilité associées aux prévisions avec des indices comme le CRPS, cela n'est pas le cas pour les prévisions DLR. La qualité de la modélisation de la partie basse de la distribution sera le critère déterminant, or il n'y a pas actuellement d'étude montrant quelle caractéristique de cette modélisation de partie basse est importante pour les gestionnaires de réseau, des paramètres de finesse ou de fiabilité pouvant être considérés, ce qui entraîne des différences importantes pour le paramétrage final.

Au lieu de validation croisée pour générer les échantillons utilisés, on travaillera alors ici avec deux échantillons, un d'entraînement et un de test, chacun associé à une année de donnée. Pour chaque méthodologie, un ensemble de modèles associés à toutes les configurations et nombres de variables possible sont générés et évalués afin d'illustrer les différences de comportement des modèles, ainsi que des informations sur les paramètres finals.

## 2.4. Sensibilité des modèles au paramétrage

### 2.4.1. Sensibilité du QLR au paramétrage

Pour la sélection de variables faite pour le QLR, on ne considère pour la sélection de variables que l'algorithme glouton. Il ne nous semble en effet pas pertinent de combiner la PCA, qui est une transformation linéaire, avec un autre modèle linéaire. Plusieurs critères d'évaluation sont considérés, illustrés sur la **Figure 2-8**. Dans un premier temps, on a considéré le CRPS. Pour cet indice, on constate une amélioration continue avec le nombre de variables, jusqu'à atteindre une valeur minimale pour 24 variables sélectionnées.

On se concentre ensuite sur l'évaluation des prévisions à bas quantile, plus importante dans le cas du DLR. On observe l'évolution du QS moyen pour les 20 premiers percentiles, les 5 premiers percentiles et le score quantile pour le premier percentile. Pour les 20 premiers percentiles, on observe un phénomène de surapprentissage qui apparaît à partir de 9 variables. On constate un même phénomène pour les cas où les 5 premiers percentiles et le premier percentile sont considérés, avec des phénomènes de surapprentissage qui apparaissent respectivement pour plus de 4 variables et plus de 1 variable. On tire de ces premiers résultats que les phénomènes de surapprentissage s'expriment de plus en plus rapidement avec le nombre de variables, lorsque l'on s'intéresse à des niveaux de probabilité de plus en plus bas.

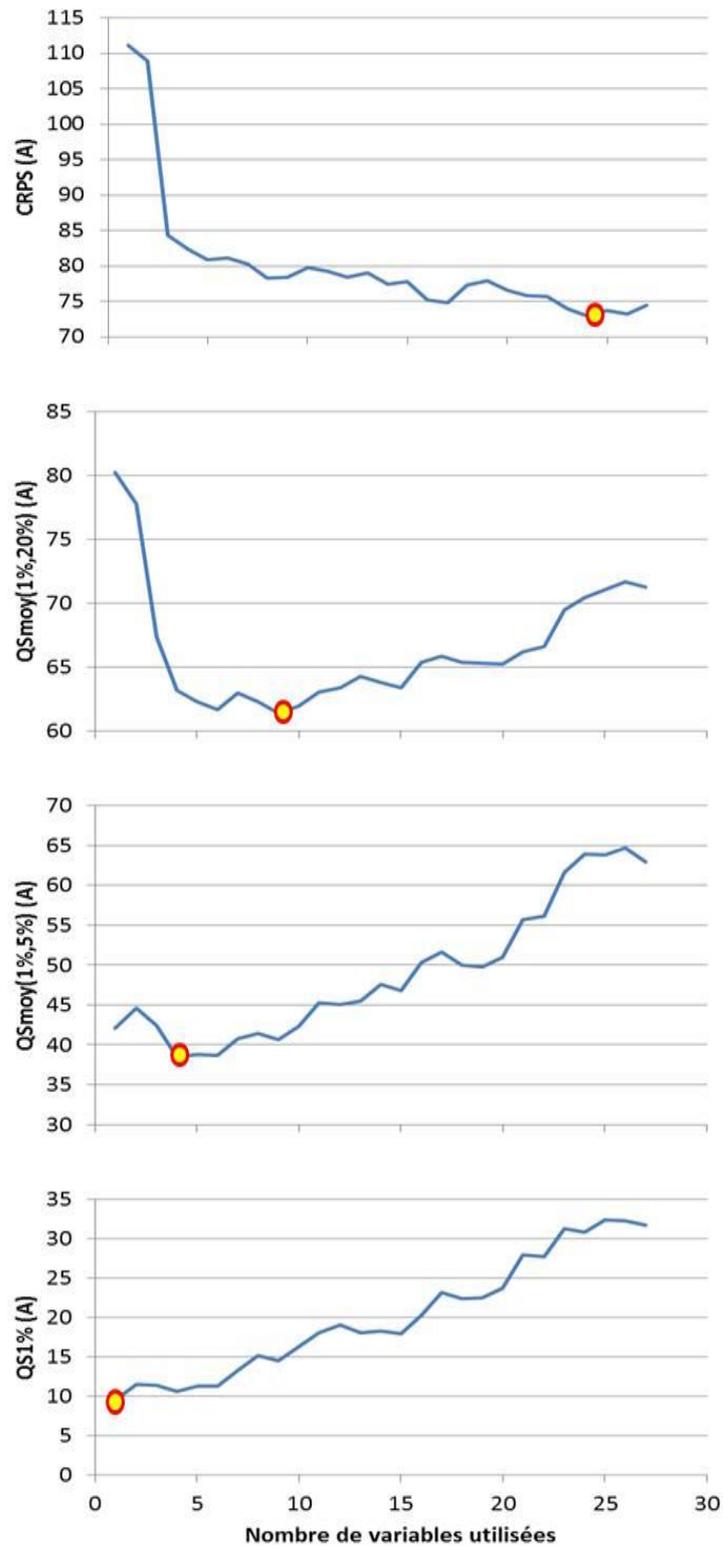
Pour fournir une visualisation plus poussée sur ces effets de surapprentissage qui diffèrent en fonction du niveau de probabilité considéré, on a représenté sur la **Figure 2-9**, l'évolution des scores quantiles, pour chaque percentile considéré, en fonction du nombre de variables utilisé pour l'entraînement du modèle. On peut alors voir que là où pour des quantiles allant de 10% à 90% un nombre de variables allant de 5 à 27 variables se traduit par des dégradations des scores quantiles inférieures à 10%, des effets de surapprentissage apparaissent tôt pour les 20 premiers et 20 derniers percentiles.

Il pourrait alors être intéressant de prendre ces effets de surapprentissage en compte, et d'entraîner des modèles aux caractéristiques différentes pour 2 types d'ensembles de quantiles :

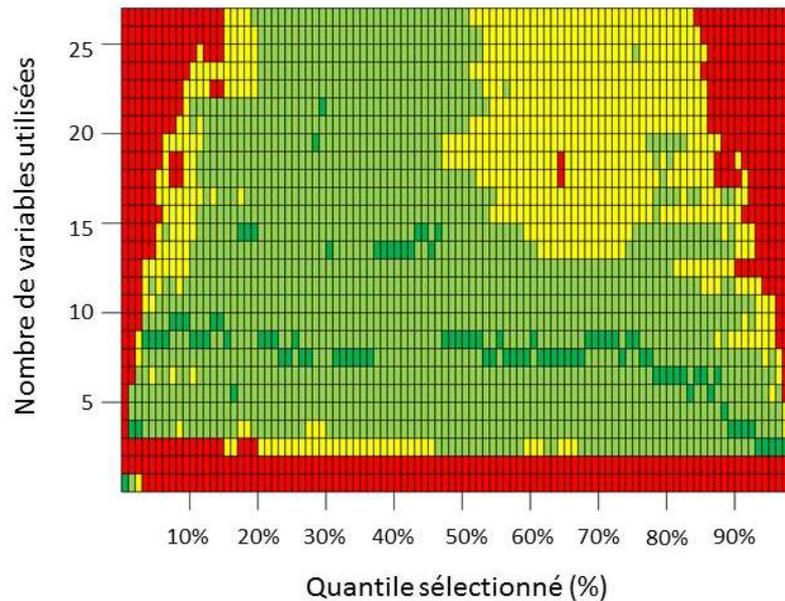
- Les prévisions pour les quantiles moyens, compris entre 20% et 80%, pour lesquels des phénomènes de surapprentissage n'apparaissent pas.
- Les prévisions à haut et bas quantile, supérieurs à 80% et inférieurs à 20%, qui nécessiteraient un paramétrage tenant compte de phénomènes de surapprentissage pouvant être importants, et utilisant alors de faibles nombres de variables.

Prenant en compte ces résultats, il serait possible de considérer que le QLR soit entraîné avec des paramètres différents quantile par quantile. Cette approche n'a cependant pas été ici choisie, et dans les résultats présentés dans la suite de ce chapitre, on entraînera le QLR avec 6 variables, ce pour tous les

percentiles, ce nombre de variables ayant permis d'obtenir de bonnes performances pour les indices  $QSmoy(1\%,20\%)$  et  $QSmoy(1\%,5\%)$ .



**Figure 2-8.** Evolution du CRPS, de  $QSmoy(1\%,20\%)$ ,  $QSmoy(1\%,5\%)$  et  $QS1\%$  pour des prévisions fournies par des modèles QLR différents à des horizons de 24 heures et moyennés sur les 8 stations considérées, avec des nombres de variable différents. Les cercles rouges représentent les minimums des différentes courbes.



**Figure 2-9.** Evolution des scores quantiles des prévisions DLR fournies avec un QLR, pour un horizon de 24 heures et moyenné sur les 8 stations considérées, en fonction du nombre de variables et du percentile sélectionné. Le code couleur suivant est utilisé : vert foncé pour les solutions optimales, vert clair pour les combinaisons entraînant une dégradation du score quantile inférieure à 5%, jaune pour une dégradation comprise entre 5% et 10% et rouge pour une dégradation supérieure à 10%.

#### 2.4.2. Sensibilité du MDNN au paramétrage

Pour les modèles précédents, l'influence du nombre de variables était le seul paramètre étudié. Ici, pour le cas du MDNN, deux autres paramètres sont ajoutés, correspondant au nombre de densités pour le mélange, et le nombre de neurones.

De manière similaire à ce qui est observé pour le modèle QLR, on observe une amélioration du CRPS pour un nombre de variables élevé, mais ce au coût d'une dégradation importante des performances du modèle sur la modélisation des parties basses des distributions de probabilité.

Pour illustrer cela, on montre sur le **Tableau 2-7** les combinaisons permettant d'obtenir des prévisions caractérisée par un CRPS inférieur à un seuil de 52A (vert), et par un  $QSmoy(1\%,20\%)$  inférieures à un seuil de 50A (rouge).

Comme on le voit, les configurations permettant d'obtenir les meilleurs résultats pour les modélisations des parties basses sont principalement des configurations simples, ayant un nombre de densités de probabilité dans le mélange ainsi qu'un nombre de variable faibles. A l'inverse, les modèles permettant d'obtenir de bons CRPS sont les modèles avec des nombres de densités et de variables élevés. On note que le paramètre du nombre de neurones dans la couche cachée, bien qu'ayant une influence, n'est pas aussi déterminant que le nombre de densités et le nombre de variables.

Pour la suite de ce travail, on sélectionne les paramètres utilisés pour le MDNN comme suit :

- On présélectionne les combinaisons permettant d'obtenir un score quantile inférieur à un seuil donné (48A).

- Parmi l'ensemble des combinaisons, on sélectionne celle qui permet d'obtenir le CRPS le plus bas.

La combinaison suivante a alors été sélectionnée : 5 variables sélectionnées avec l'algorithme glouton, 1 neurone et 2 densités gaussiennes définissant le mélange.

**Tableau 2-7.** Illustration de l'influence des paramètres du MDNN sur les performances du modèle. Les cases rouges représente les configurations permettant d'avoir une valeur de  $Q_{Smoy}(1\%,20\%)$  inférieure à un seuil donné, ici 50A, les cases vertes les situations où le CRPS est inférieur à un seuil donné, ici 52A, et en orange les situations permettant de respecter les deux critères.

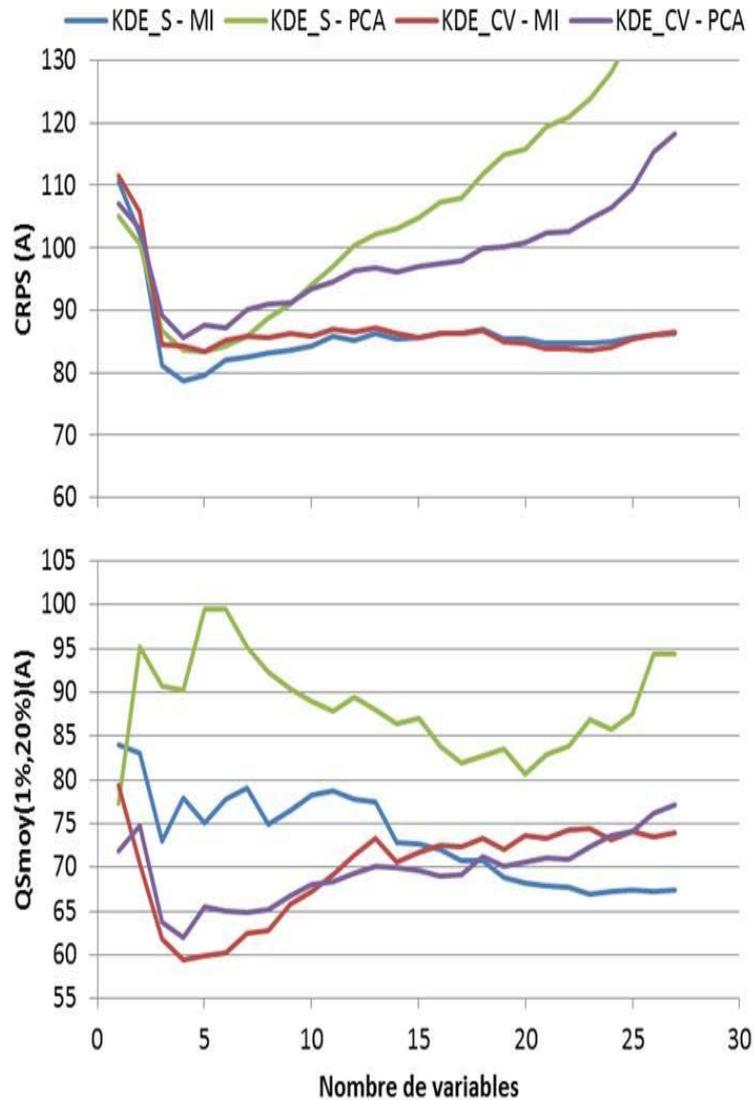
		Nombre de densités (m) / Nombre de neurones (h)															
		1				2				3				4			
m	h	0	1	2	3	0	1	2	3	0	1	2	3	0	1	2	3
Nombre de variables	1																
	2																
	3																
	4																
	5																
	6																
	7																
	8																
	9																
	10																
	11																
	12																
	13																
	14																
	15																
	16																
	17																
	18																
	19																
	20																
	21																
	22																
	23																
	24																
	25																
	26																
	27																

### 2.4.3. Sensibilité du KDE au paramétrage

Pour l'étude de l'influence du nombre de variables sur la performance de l'estimateur par noyau, on considère comme avec les modèles précédents des variables sélectionnées avec les deux méthodologies évoquées. Dans un premier temps, on compare alors les performances des modèles en fonction du traitement des variables, mais aussi de la méthodologie utilisée pour calculer le paramètre de lissage,

défini à l'aide d'une méthode analytique observant la règle de Silvermann (S), ou à l'aide d'une validation croisée (CV) (**Figure 2-10**).

Une évaluation avec le CRPS permettrait dans un premier temps de considérer la méthode de Silvermann comme offrant de meilleures performances que la méthode par validation croisée. Cependant, cela s'accompagne d'une dégradation importante sur la modélisation des quantiles bas, et on préférera alors fixer le paramètre de lissage à partir d'une validation croisée.

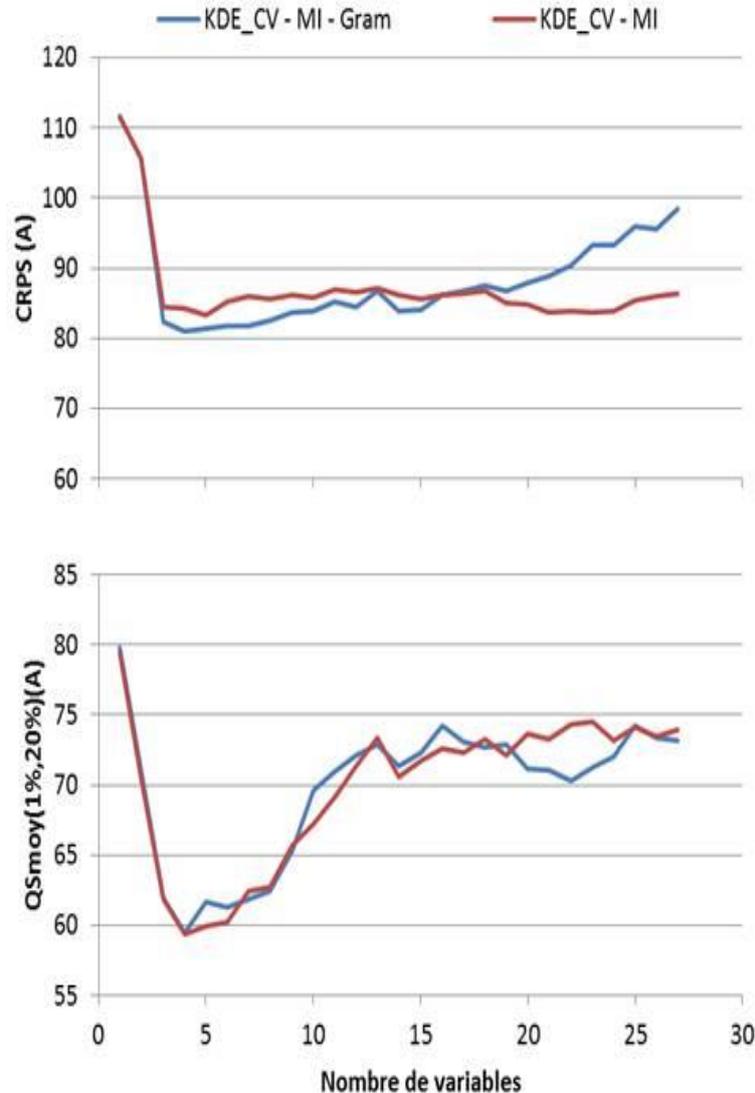


**Figure 2-10.** Comparaison du CRPS et du QSmoy(1%,20%) pour différents modèles de KDE entraînés à des horizons de 24 heures et moyennés sur les 8 stations considérées, avec un nombre arbitraire de variables sélectionnées avec l'algorithme glouton et la PCA, et un paramètre de lissage obtenu soit par la méthode de Silvermann, soit par une validation croisée.

Cependant, après la sélection des variables et avant leur normalisation par rapport à l'écart-type, on considère l'ajout ou non d'un traitement des données avec un algorithme de Gram-Schmidt (**Figure 2-11**). Ce procédé est similaire au traitement par analyse par composante principale, mais les variables sont par la suite toutes conservées.

L'idée de cet ajout repose sur la volonté d'adapter les variables utilisées au format de matrice de lissage sélectionné pour l'estimateur de densité par noyau, ici une matrice diagonale.

L'étude de l'évolution du CRPS en fonction du nombre de variables pour le KDE montre une forte sensibilité au surapprentissage, en particulier lorsque les variables sont traitées avec une PCA. Le CRPS atteint son minimum pour 7 variables fournies par la PCA, et on utilisera donc pour la suite des KDE entraînés avec cette configuration.



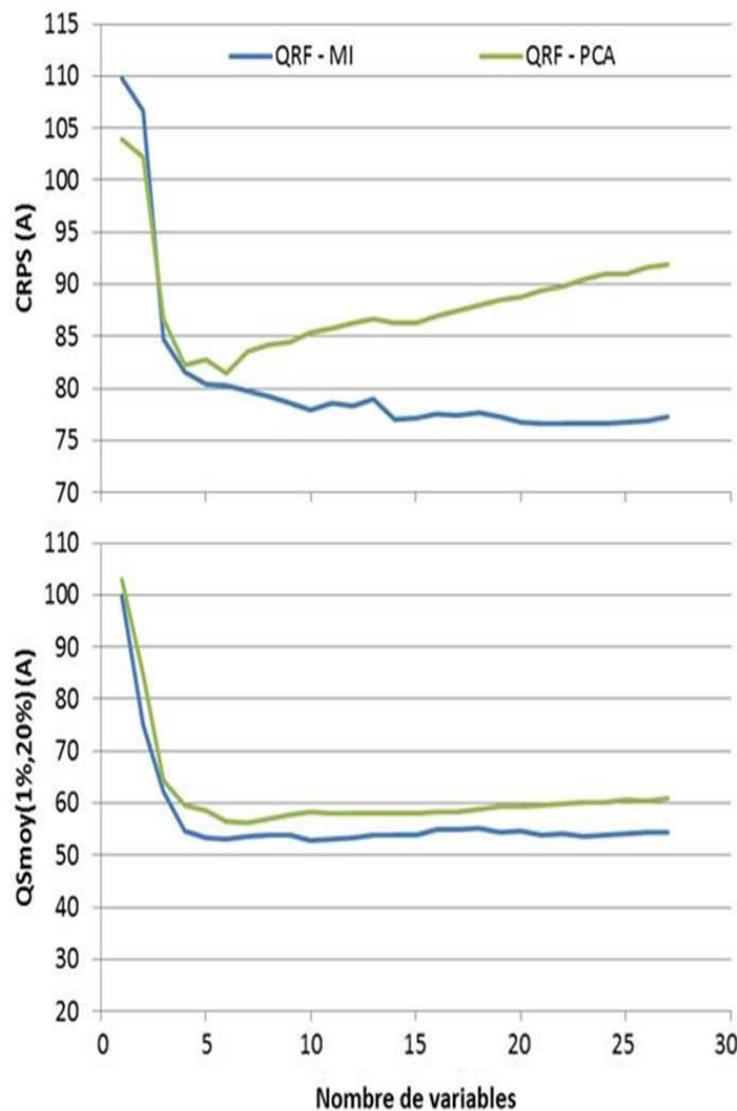
**Figure 2-11.** Comparaison du CRPS du QSmoy(1%,20%) pour différents modèles de KDE entraînés à des horizons de 24 heures et moyennés sur les 8 stations considérées, avec un nombre arbitraire de variables sélectionnées avec l'algorithme glouton et la PCA, et un paramètre de lissage obtenu par la méthode de Silvermann ou une validation croisée.

#### 2.4.4. Sensibilité du QRF au paramétrage

Sur la **Figure 2-12**, on a représenté les résultats associés à l'influence d'une variation du nombre de variables sur les performances du modèle, en fonction de si celle-ci ont été sélectionnées avec l'algorithme glouton ou avec une PCA.

Avec des variables non modifiées, le QRF apparaît comme relativement peu influencé par le nombre de variables. Par rapport au CRPS (**Figure 2-12**), on observe qu'il y a un optimum pour 13 variables, mais le phénomène de surapprentissage reste faible et une faible dégradation de l'indice se produit lorsque le nombre de variables est doublé. Il est à noter que cette résilience est encore marquée pour l'évolution de la partie basse de la distribution **Figure 2-12**.

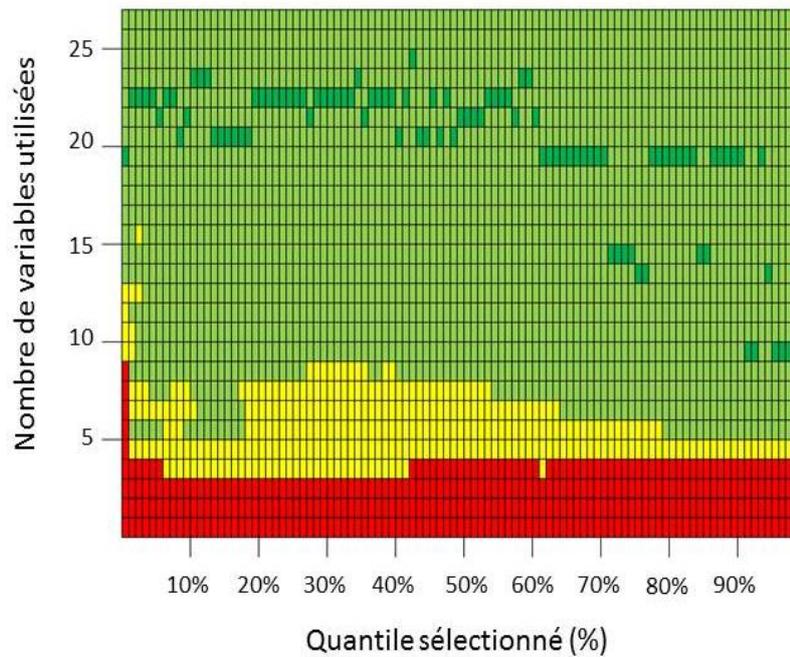
Avec des variables modifiées par PCA, il y a une dégradation significative de la qualité des modèles. Cela est dû au fait que la PCA concentre l'information sur un nombre limité de variables, et que ces variables peuvent ne pas être utilisées par certains arbres du modèle, en raison du processus de sélection aléatoire de variable fait à chaque nœud des arbres. Avec le QRF et le GBRT, nous travaillerons donc par la suite sans utiliser de PCA.



**Figure 2-12.** Comparaison des évolutions du CRPS et du QSmoy(1%,20%) pour différents modèles de QRF entraînés à des horizons de 24 heures et moyennés sur les 8 stations considérées, avec un nombre arbitraire de variables sélectionnées avec l'algorithme glouton et la PCA.

En addition à ces considérations, nous avons aussi refait une analyse similaire à celle faite sur le QLR présentée dans la **Figure 2-9**, illustrée sur la **Figure 2-13**. On constate que le QRF ne présente pas les

mêmes comportements que les modèles précédemment évoqués, aucun surapprentissage n'apparaissant à la fois pour les quantiles médians et les quantiles des queues de distribution.

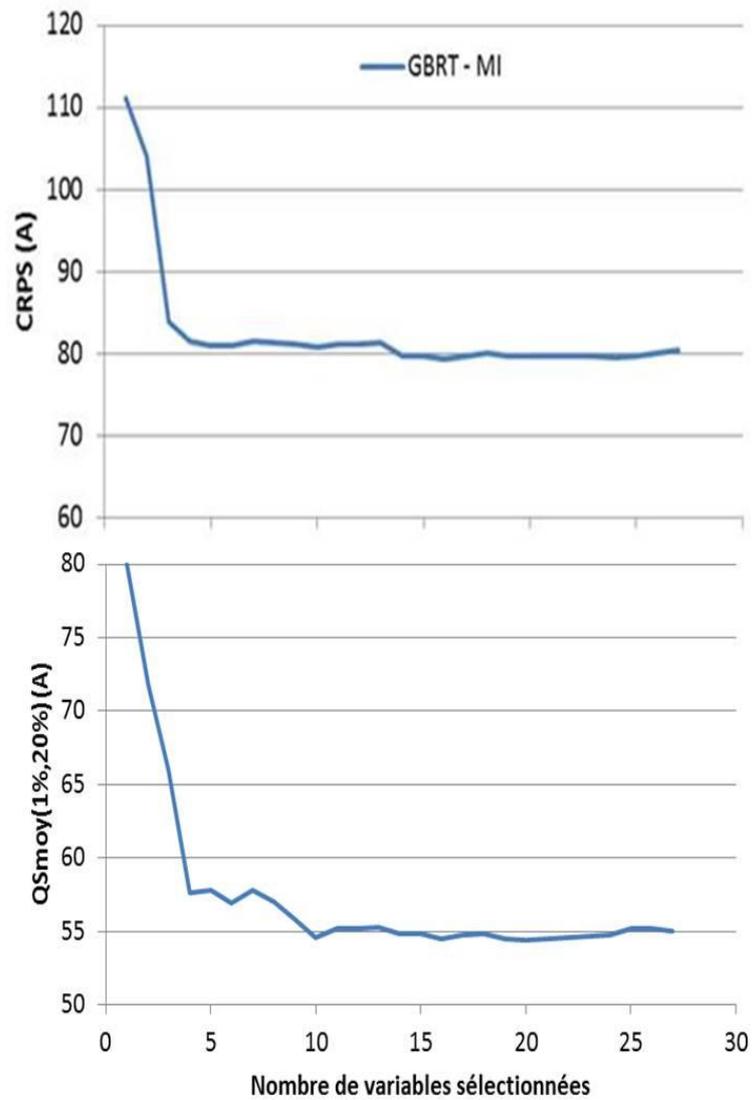


**Figure 2-13.** Evolution des scores quantiles des prévisions DLR fournies avec un QRF, pour un horizon de 24 heures et moyenné sur les 8 stations considérées, en fonction du nombre de variables et du percentile sélectionné. Le code couleur utilisé est le même que sur la **Figure 2-9**.

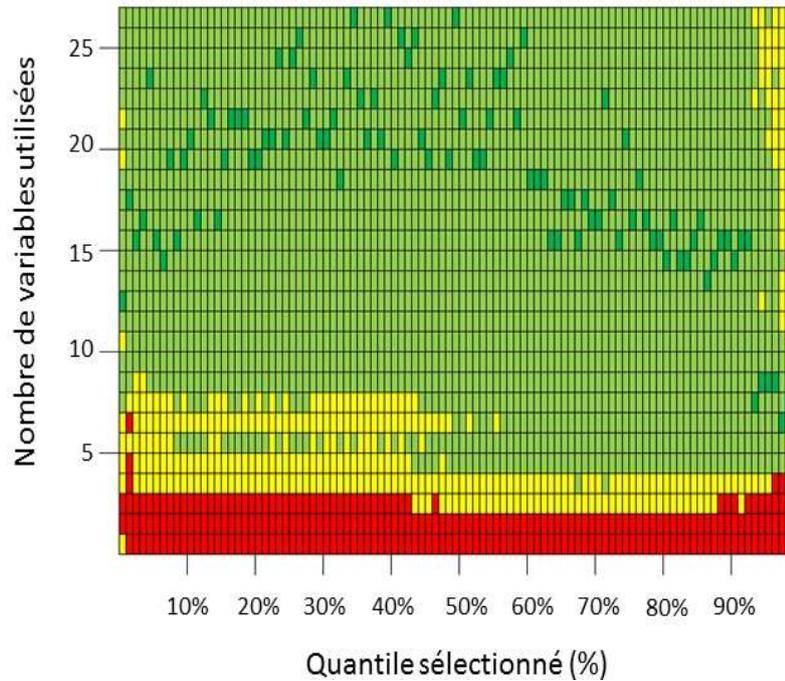
#### 2.4.5. Sensibilité du GBRT au paramétrage

Pour le GBRT, la méthode étant ensablée, on note des résultats similaires à ceux observés pour le QRF au niveau de la résistance au surapprentissage, comme illustré sur la **Figure 2-14**. Le modèle apparaît comme peu sensible au surapprentissage, et nous avons considéré l'utilisation de l'ensemble des variables pour l'utilisation de ce modèle.

On note cependant, comme vu sur la **Figure 2-15**, de légers effets de surapprentissage, en particulier pour les quantiles hauts, avec par exemple le score quantile pour des prévisions à 99% augmentant de plus de 5 % lors d'un passage de 8 variables à 27. Dans ce chapitre, nous utiliserons le GBRT avec le maximum de variables, nonobstant ces dégradations.



**Figure 2-14.** Comparaison du CRPS du  $Q_{\text{Smoy}}(1\%,20\%)$  pour différents modèles de GBRT entraînés à des horizons de 24 heures et moyennés sur les 8 stations considérées, avec un nombre arbitraire de variables sélectionnées avec l'algorithme glouton.

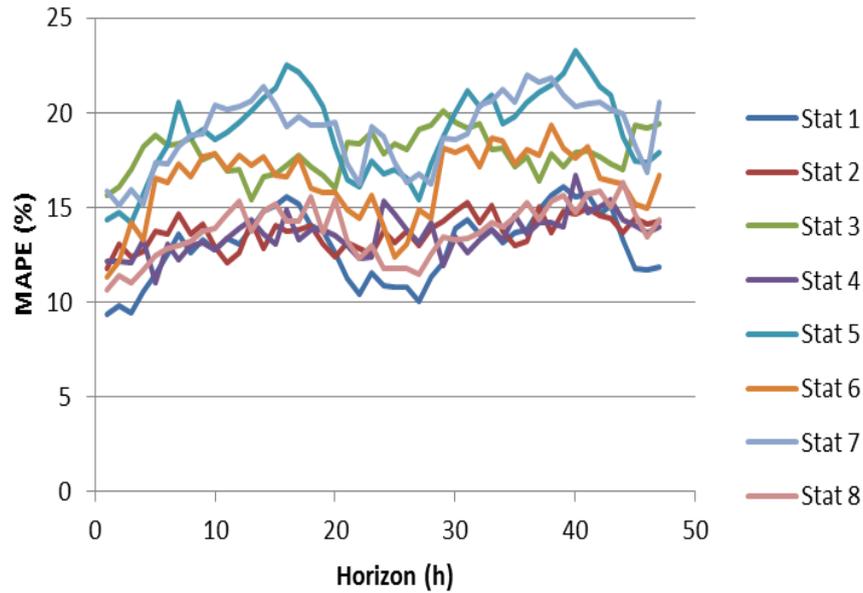


**Figure 2-15.** Evolution des scores quantiles des prévisions DLR fournies avec un GBRT, pour un horizon de 24 heures et moyennées sur les 8 stations considérées, en fonction du nombre de variables et du percentile sélectionné. Le code couleur utilisé est le même que sur la **Figure 2-9**.

## 2.5. Evaluation des modèles

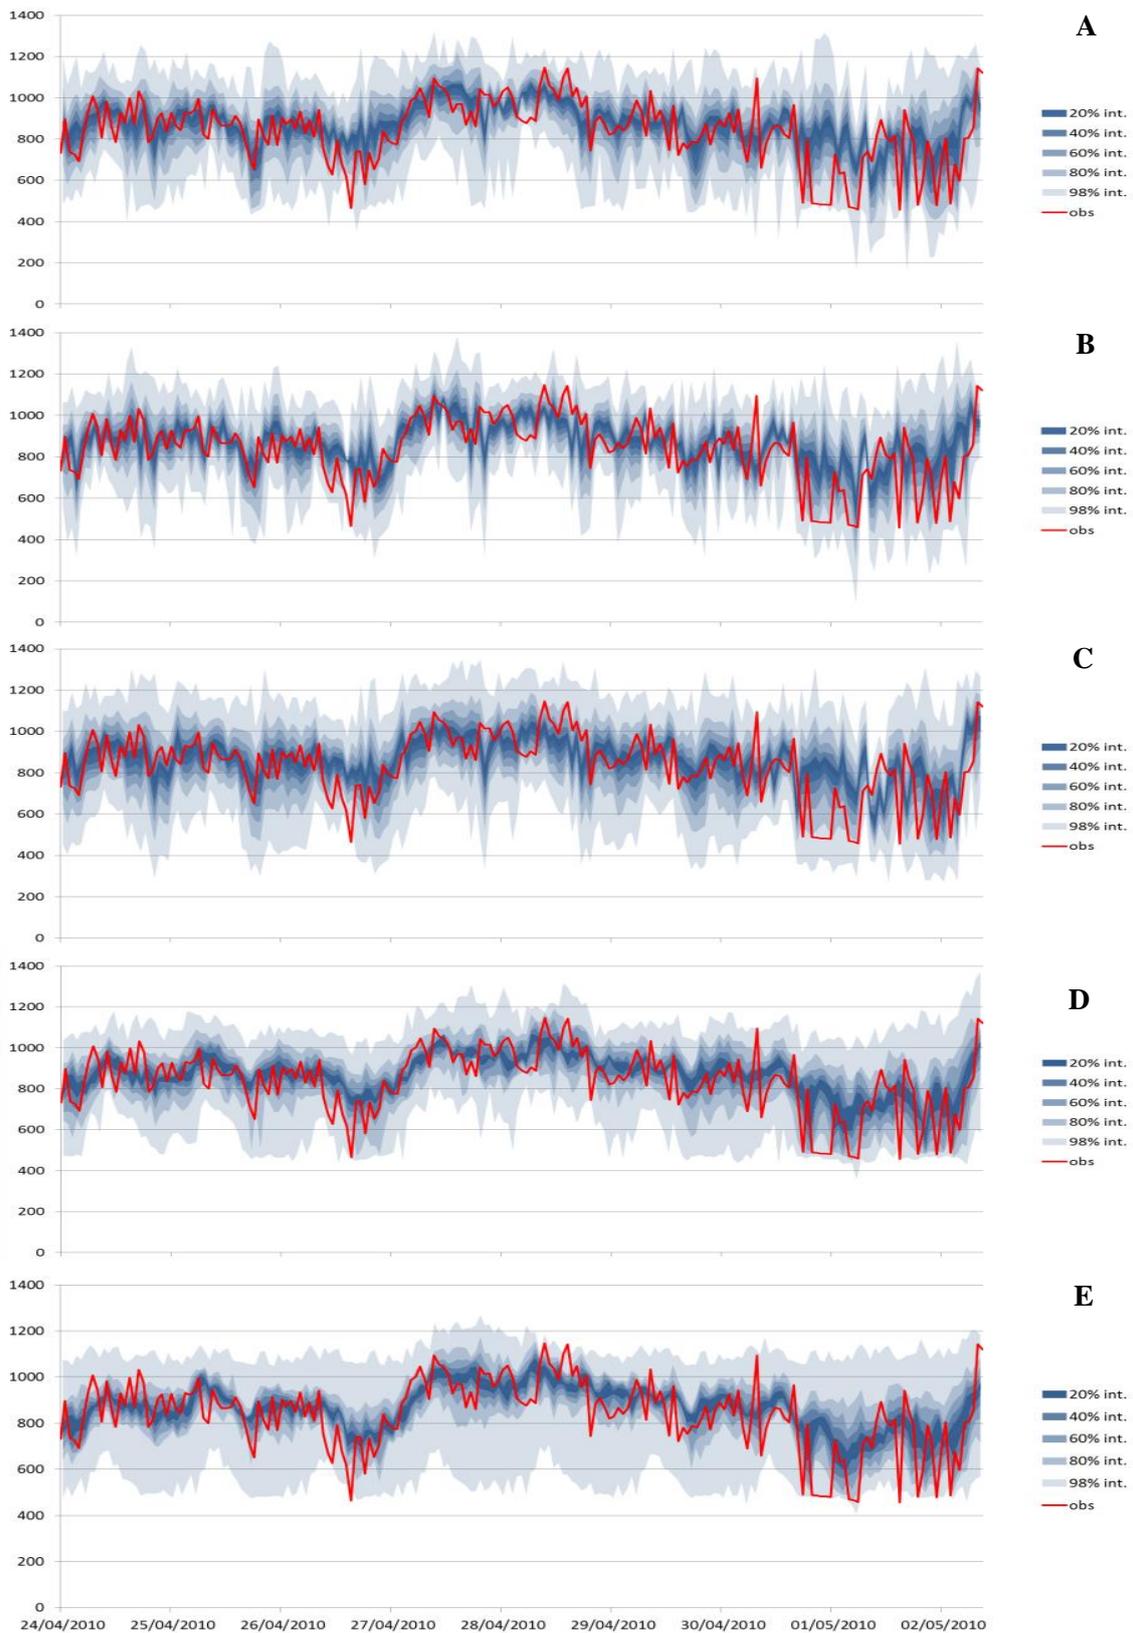
On utilise les modèles pour générer des prévisions toutes les 24 heures à 12h00 pour des horizons allant de 1 heure à 48 heures. Les modèles sont entraînés pour chacune des 8 stations météorologiques.

Comme on peut le voir sur la **Figure 2-16**, où on évalue les MAPE associées à des prévisions QRF pour chaque station, on constate une forte variabilité des indices d'une station à l'autre, avec par exemple des MAPE pour une prévision à 24 heures faite sur les stations 1 à 8 allant de 11% à 18%. Pour cette raison, nous travaillerons par la suite avec les valeurs moyennes des indices statistiques sur les huit différentes stations.



**Figure 2-16.** Comparaison de l'évolution du MAPE pour différents modèles de prévision de type QRF, fournissant des prévisions pour les 8 stations considérées et pour des horizons allant de 1 à 48 heures.

Afin d'illustrer les prévisions sur lesquelles nous travaillons, sur la **Figure 2-17**, on représente différentes prévisions faites pour une station météorologique et une période donnée, différentes méthodes de prévision étant utilisées.



**Figure 2-17.** Exemple de prévisions RTLRL pour la station météo 1, pour une période allant du 24/04/2010 au 02/05/2010, fournies avec un QLR (A), un MDNN (B), un KDE (C), un QRF (D) et un GRBT (E). Les prévisions sont faites tous les jours à 12h00, pour des horizons de prévision allant de 24 heures à 47 heures.

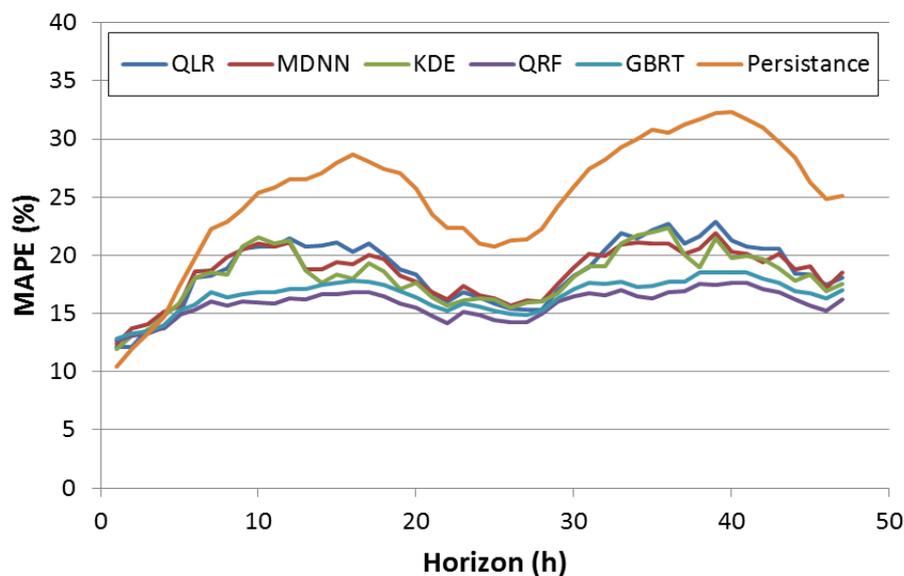
### 2.5.1. Evaluation des modèles sur des critères déterministes

Il n'existe actuellement pas d'étude mettant en avant des comparaisons entre des modèles probabilistes pour le RTL. En revanche, dans [48], les auteurs comparent les capacités de différentes méthodologies à fournir des prévisions RTL moyennes.

Le cas d'étude considéré est le même que le nôtre, même si les stations considérées divergent de celles observées ici. De plus, il est à noter que les auteurs s'intéressent à des prévisions faites en continu, toutes les 15 minutes, là où nous travaillons avec des prévisions faites toutes les 24 heures.

On pose cependant que les améliorations observées pour l'indice du MAPE peuvent servir de point de comparaison pour évaluer nos modèles. Dans l'étude et pour un horizon de 24 heures, avec des valeurs de MAPE proche de 25% pour le modèle persistance donnant des prévisions égales aux observations à  $t=0$ , les auteurs proposent des modèles ayant des MAPE proches de 15%.

Cela correspond à ce qui est observé dans notre cas (**Figure 2-18**), et nous permet de valider la qualité de nos approches par rapport à l'état de l'art en ce qui concerne la capacité de nos modèles à fournir des prévisions déterministes.



**Figure 2-18.** Comparaison de l'évolution du MAPE pour différents modèles de prévision, fournis avec les 5 méthodologies considérées et un modèle persistance. Les indices sont calculés en faisant la moyenne des MAPE observés pour les 8 stations différentes, pour des horizons de prévision allant de 1 à 48 heures.

### 2.5.2. Evaluation des modèles sur des critères probabilistes

#### 2.5.2.1. Fiabilité des modèles

Un critère déterminant pour des modèles probabilistes est la fiabilité. On l'évalue ici avec des histogrammes PIT, focalisés d'abord sur l'ensemble de la distribution (**Figure 2-19.A**), ensuite seulement sur la partie basse (**Figure 2-19.B**).

Les histogrammes PIT (*Probability Integral Transform*) sont des outils qui permettent d'évaluer la fiabilité de modèles de prévision. Pour un intervalle de probabilité donné  $[\tau_1, \tau_2]$ , l'histogramme PIT permet d'illustrer la proportion des observations qui ont été observées entre les prévisions quantiles  $\hat{Y}_{t+h|t}^{\tau_1}$  et  $\hat{Y}_{t+h|t}^{\tau_2}$ . Ainsi, si la valeur de la barre atteint  $\alpha\%$ ,  $\alpha\%$  valant 100% dans le cas d'une fiabilité parfaite étant observée, il y aurait  $\alpha \cdot (\tau_2 - \tau_1)\%$  des observations qui seraient comprises entre les prévisions quantiles  $\hat{Y}_{t+h|t}^{\tau_1}$  et  $\hat{Y}_{t+h|t}^{\tau_2}$ .

On fera remarquer qu'un modèle de prévision peut être parfaitement fiable, même si  $\alpha$  n'atteint pas 100%. Par exemple, avec 10000 prévisions aux erreurs indépendantes et parfaitement fiables, et pour le quantile  $\tau=1\%$ , il y a 1% de probabilité que 1.24% des observations soient surestimées par des prévisions quantiles 1%.

En effet, en accord avec des lois binomiales, des déviations peuvent être observées, et on peut estimer alors que pour un niveau de probabilité  $\tau$ , la proportion d'observations supérieures à une prévision quantile  $\tau$  a une probabilité  $\beta$  d'être supérieure à une valeur  $\tau \cdot \alpha_\tau^\beta$ . Considérant une absence totale de corrélation entre les erreurs de prévision, on représente des exemples de valeurs de  $\alpha_\tau^\beta$  fonction du nombre d'échantillons sur le **Tableau 2-8**. Les résultats ne pouvant être calculés pour des échantillons trop importants avec des calculs considérant les formules des lois binomiales, les résultats sont obtenus avec 2000 tirages aléatoires associés à des échantillons de taille variable et dont les valeurs des observations sont binaires. Les valeurs de ces observations sont fixées égales à 1 de manière aléatoire, avec un niveau de probabilité  $\tau$ .

**Tableau 2-8.** Exemple de valeurs de  $\alpha_\tau^\beta$ , fonction des nombres de prévisions considérées.

	$\tau = 0.1\%$		$\tau = 0.5\%$		$\tau = 1\%$		$\tau = 2\%$	
<b>Nombre de prévisions</b>	$\beta = 1\%$	$\beta = 99\%$	$\beta = 1\%$	$\beta = 99\%$	$\beta = 1\%$	$\beta = 99\%$	$\beta = 1\%$	$\beta = 99\%$
<b>100</b>	0%	1000%	0%	400%	0%	400%	0%	300%
<b>1000</b>	0%	400%	20%	200%	40%	180%	55%	155%
<b>10000</b>	30%	190%	68%	138%	78%	124%	84%	117%
<b>50000</b>	70%	130%	86%	116%	90%	110%	93%	107%

Dans cette partie, on considère l'ensemble des prévisions pour des horizons allant de 24 heures à 48 heures, ce pour toutes les stations. Les valeurs des barres correspondent aux valeurs moyennes observées pour cet échantillon de prévision, et les barres correspondent aux écart-types observés par rapport à la dispersion de ces valeurs de fréquence relative, pour les mêmes types de données non plus pour toutes les stations mais seulement station par station.

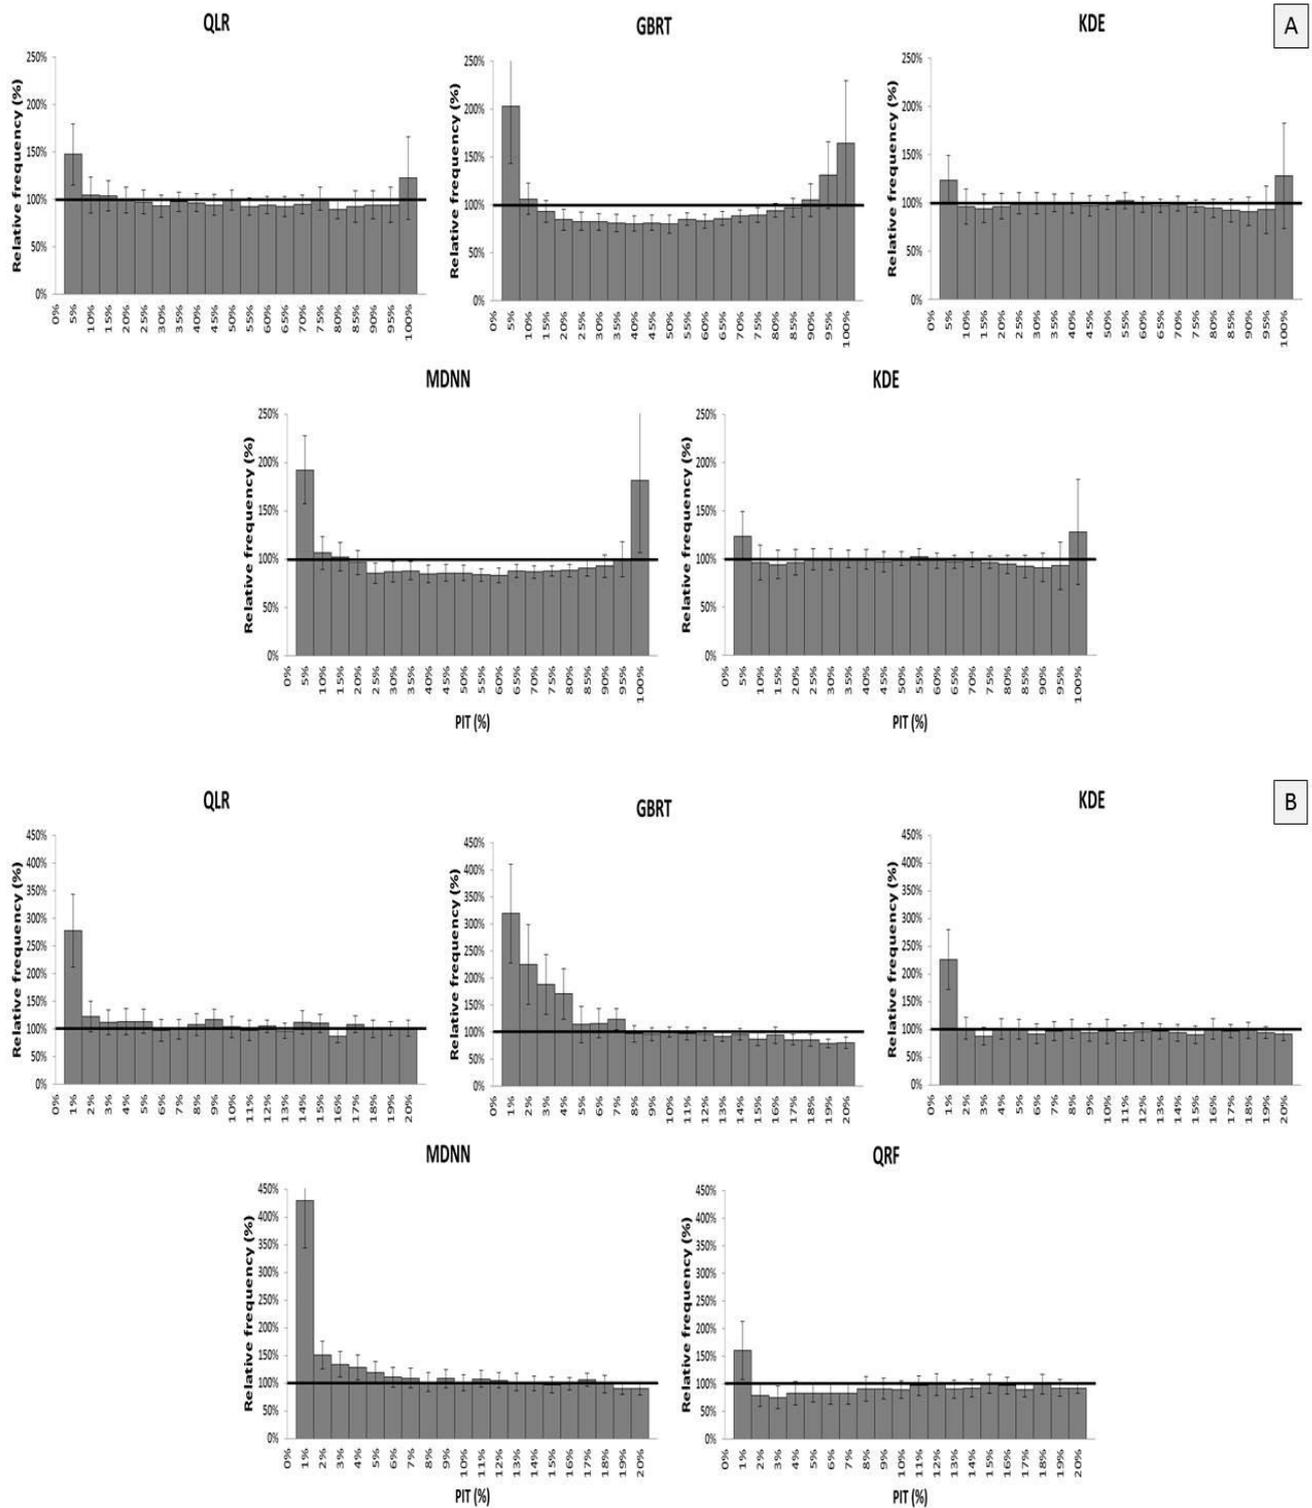
On peut constater sur la **Figure 2-19** que les distributions sont relativement bonnes sur les parties centrales, et se dégradent fortement pour les parties basses et les parties hautes des distributions, à l'exception de ce qui est observé pour le modèle QRF.

Considérant une utilisation de prévisions RTLR pour un quantile fixé à 5%, le MDNN et le GBRT apparaissent même comme non viables, en raison d'une fréquence de surestimations des prévisions proche de 10%.

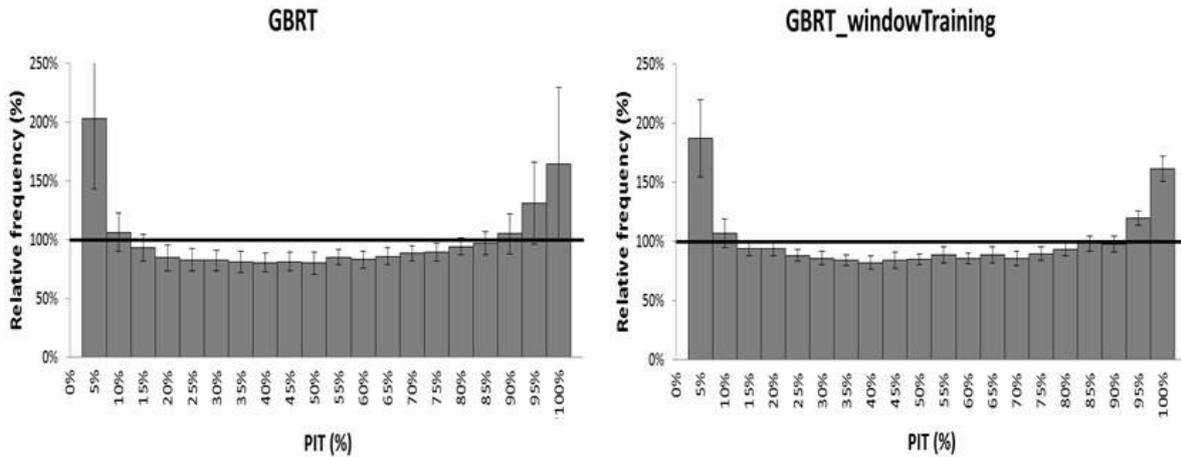
On fera remarquer que la nature de la construction des échantillons d'entraînement des modèles a un impact faible sur ces fréquences. Sur la **Figure 2-20**, on représente les diagrammes de fiabilité pour deux modèles de GBRT créés avec des prévisions faites pour les mêmes ensembles de donnée que sur la **Figure 2-19**. Le premier modèle est entraîné avec un échantillon d'entraînement fixe correspondant à un an de données, et l'autre avec des échantillons d'entraînement réactualisés tous les mois avec un procédé de fenêtre glissante correspondant à un an de données. Même si de légères améliorations sont obtenues, la fréquence de surestimations des prévisions quantiles à 5% passant de 10% à 9%, cette amélioration reste relativement faible.

On remarque aussi sur la **Figure 2-19** que les fiabilités erronées pour les quantiles bas sont concentrées pour les niveaux de probabilité inférieurs à 1%.

Une question se pose alors, celle de la qualité de la fiabilité des modèles au regard des exigences des opérateurs de réseau. Les critères de fréquence de 5% et 10% de [51], [76] peuvent aisément être respectés, là où cela peut être plus compliqué pour le critère de 1% utilisé dans [73].



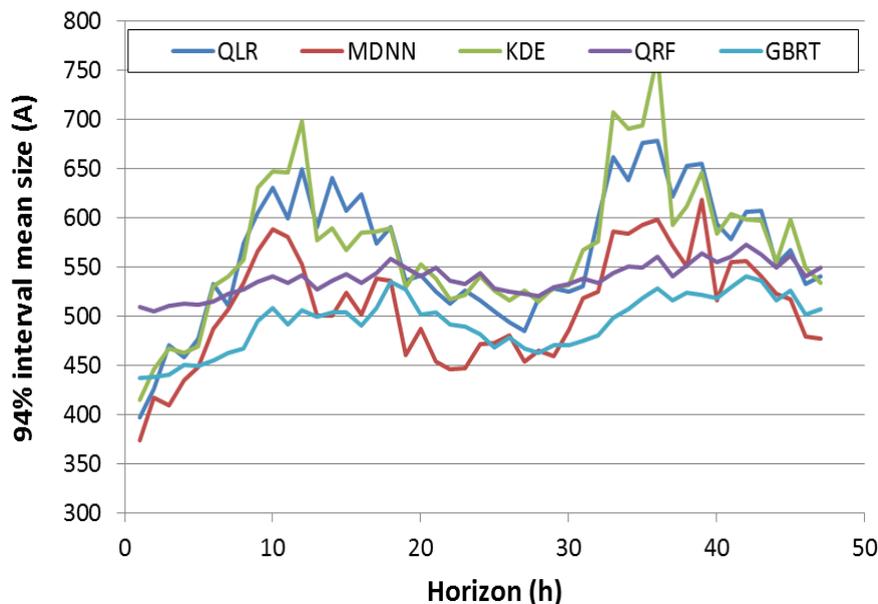
**Figure 2-19.** Diagrammes PIT pour les 5 différents modèles considérés. Pour calculer la fiabilité, on considère la fréquence relative des prévisions associées aux fréquences considérées supérieures aux observations, ce pour l'ensemble des prévisions faites sur les 8 stations différentes, avec des horizons allant de 24 à 48 heures. On représente avec les barres d'erreur les écarts-types associés aux variations de valeurs de fiabilité entre les différentes stations. Sur la **Figure 2-19.A**, on représente les diagrammes PIT pour les quantiles allant de 0 à 100%, et sur la **Figure 2-19.B**, les diagrammes PIT pour les quantiles allant de 0 à 20%.



**Figure 2-20.** Diagrammes PIT pour des prévisions fournies par 2 différents modèles de GBRT, avec les mêmes considérations que sur la **Figure 2-19**. Sur le diagramme de gauche, le modèle est entraîné à l'aide d'un échantillon d'entraînement fixe, comprenant des données collectées sur une année. Pour le deuxième à droite, le modèle est entraîné avec des échantillons d'entraînement réactualisés tous les mois, en utilisant une fenêtre glissante correspondant à une année de données.

### 2.5.2.2. Finesse

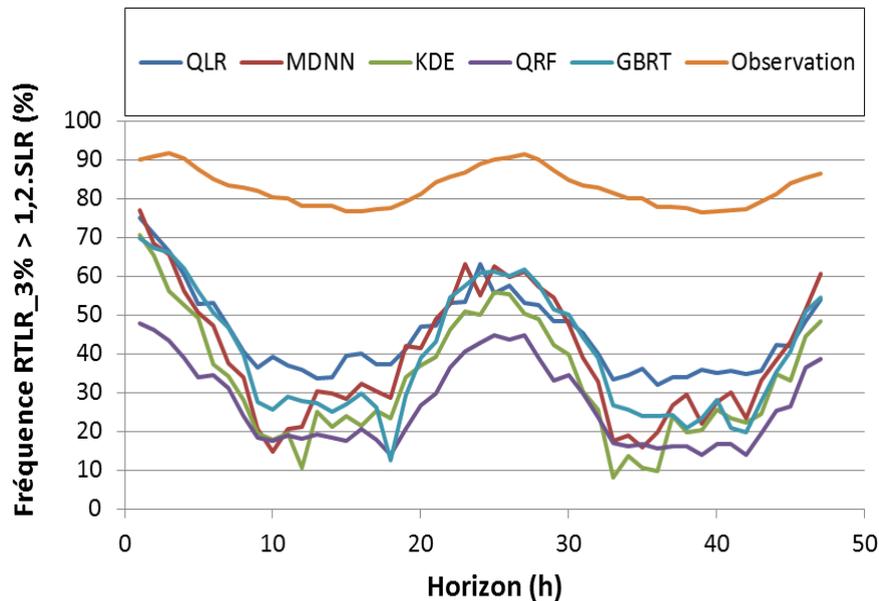
Un deuxième paramètre à évaluer pour des modèles probabilistes est la finesse des modèles. On peut évaluer celle-ci comme étant liée à la largeur des intervalles de précision. On représente sur la **Figure 2-21** la taille moyenne des intervalles de précision à 94%, c'est-à-dire la différence moyenne entre les prévisions à 3% et à 97%. La valeur moyenne de ces intervalles est calculée sur les prévisions faites pour l'ensemble des stations météorologiques.



**Figure 2-21.** Taille moyenne des intervalles  $[\hat{Y}_{t_k+h|t_k}^{3\%}, \hat{Y}_{t_k+h|t_k}^{97\%}]$  pour différents modèles de prévision, fournis avec les 5 méthodologies considérées. Les indices sont calculés en faisant la moyenne des MAPE observés pour les 8 stations différentes, pour des horizons de prévision allant de 1 à 48 heures.

On trouve que le MDNN fournit des prévisions ayant une bonne finesse, ce qui est à mettre en parallèle avec sa mauvaise fiabilité. Un autre point notable est le fait que le QRF a une assez bonne finesse, meilleure que le QLR et le KDE, et ce tout en ayant une bonne fiabilité comme on l'a vu dans la partie précédente.

Par la suite, nous nous sommes intéressés au lien entre le gain fourni par des prévisions RTLR, et la finesse des prévisions. Ainsi, dans la **Figure 2-22**, on a évalué les fréquences associées à des dépassements d'une valeur seuil, ici 120% du SLR, par une observation RTLR et une prévision RTLR définie avec un niveau de fréquence de 3%.



**Figure 2-22.** Fréquence de situations où  $\hat{Y}_{t_k+h|t_k}^{3\%} \geq \text{SLR}$  pour différents modèles de prévision, fournis avec les 5 méthodologies considérées. Les indices sont calculés en faisant la moyenne des MAPE observés pour les 8 stations différentes, pour des horizons de prévision allant de 1 à 48 heures.

On représente les fréquences de dépassement comme les moyennes de celles observées pour l'ensemble des stations. En réalité, ces fréquences ne correspondent pas à des situations réalistes d'utilisation du DLR : au vu de la sélection d'une section critique de ligne, il faudrait en fait observer les dépassements des valeurs minimales de RTLR sur les 8 stations par rapport aux prévisions à 3% minimales fournies pour les 8 stations. Il est alors à noter que là où le modèle MDNN permettait d'obtenir des prévisions probabilistes avec de relativement bonnes finesses, mais que cela ne se traduit pas par une amélioration significative du nombre de situations où la prévision RTLR dépasse les 120% du SLR, surtout par rapport au modèle QLR qui est meilleur que le MDNN sur ce critère en dépit d'une moins bonne évaluation de sa finesse.

On peut aussi souligner une différence remarquable qui apparaît entre la prévision du DLR et d'autres types de prévision. En effet, on peut constater que là où pour des horizons à 24 heures on obtient en moyenne un maximum local pour le nombre d'améliorations permises par le DLR, on constate aussi un minimum local pour la taille des intervalles à 94%.

Pour résumer simplement cette tendance contre-intuitive qui a été observée dans nos cas d'étude, plus une prévision moyenne DLR est grande, moins il y a d'incertitudes sur celle-ci. Cela est principalement dû au fait que les prévisions à haut quantile évoluent relativement peu avec les prévisions

météorologiques, là où les prévisions à bas quantiles sont beaucoup plus sensibles à ces paramètres. Si on considère les prévisions à haut quantiles comme fixes, on comprend alors que la finesse des intervalles décroît seulement lorsque les prévisions à bas quantile sont élevées et proches des prévisions à haut quantile.

### 2.5.3. Indice d'évaluation des prévisions probabilistes

On a vu préalablement que différents modèles pouvaient avoir de bonnes performances, soit pour la fiabilité (QLR, QRF et KDE), soit pour la finesse (MDNN).

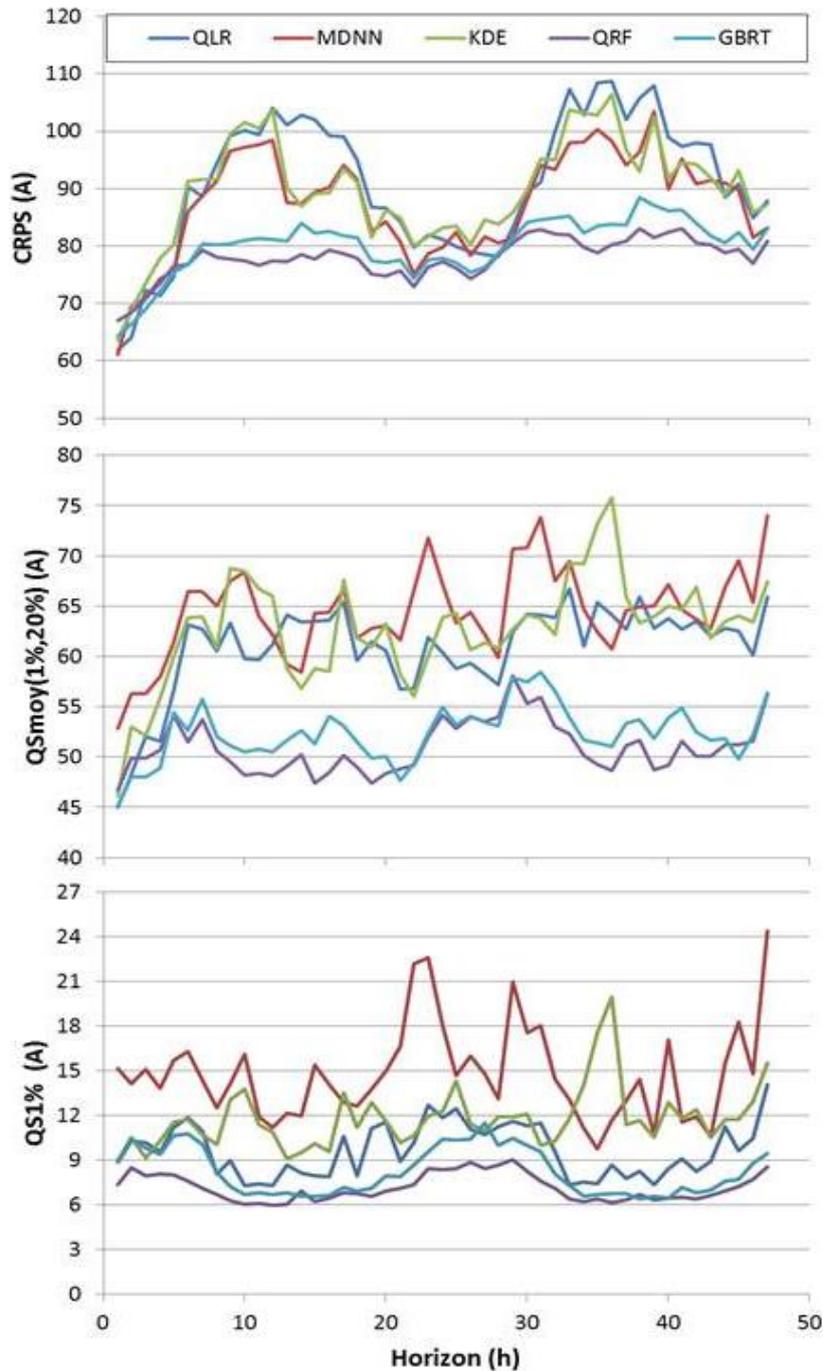
Afin de trancher entre ces différents modèles, une première approche est l'utilisation des indices d'évaluation de prévisions probabilistes tels que le CRPS. On considère aussi des scores quantiles moyen sur les 20 premiers percentiles, et le score quantile pour le premier percentile (**Figure 2-23**).

Comme on le voit sur la **Figure 2-23**, le modèle QRF réussit à supplanter les autres modèles sur l'ensemble des indices que nous avons considérés.

Dans le cas du CRPS, cette différence est en grande partie due au fait que lorsque les modèles ont été paramétrés, on a choisi des combinaisons permettant d'optimiser les modélisations des parties basses des distributions. Par exemple pour un horizon de 36 heures, on voit sur la **Figure 2-23** que le CRPS pour le modèle linéaire entraîné avec 6 variables est égal à 109A. Cependant, si celui-ci avait été entraîné avec 27 variables, le CRPS aurait alors été égal à 90A. Avec les 4 autres méthodes, un modèle différent devrait être paramétré pour chaque quantile.

Pour la modélisation de la partie basse, pour l'optimisation de laquelle les modèles ont été paramétrés, on voit que le QRF réussit aussi à dépasser les 4 autres modèles.

Pour la comparaison avec les QLR, MDNN et KDE, cela est dû à la nature du modèle : celui-ci est basé sur une méthode ensembliste, peu sensible au surapprentissage, et le QRF peut alors utiliser toute l'information des variables utilisées. A l'inverse avec les trois autres modèles, l'information doit être limitée pour éviter un surapprentissage, phénomène apparaissant rapidement sur la modélisation de la partie basse de la distribution.



**Figure 2-23.** Comparaison de l'évolution du CRPS, de  $Q_{Smoy}(1\%,20\%)$  et de  $Q_{Smoy}(1\%,5\%)$  pour différents modèles de prévision, fournis avec les 5 méthodologies considérées. Les indices sont calculés en faisant la moyenne des MAPE observés pour les 8 stations différentes, pour des horizons de prévision allant de 1 à 48 heures.

Par rapport à la comparaison entre le GBRT et le QRF, le calibrage non optimisé du GBRT apparaît comme la première raison pouvant justifier la plus faible performance du GBRT. Une hypothèse non développée dans nos travaux est aussi le fait que comme cela a été vu pour le QLR, des erreurs de variance semblent apparaître très rapidement pour les modélisations des quantiles très bas, et le GBRT pourrait être plus sensible à ce phénomène que le QRF.

Dans la section 5.7.3, nous référons une comparaison entre les 5 différents modèles proposés avec une évaluation de la valeur financière des prévisions fournies. Au vu des résultats obtenus dans ce chapitre, le modèle QRF proposé sera proposé comme modèle par défaut pour les travaux présentés dans les chapitres suivants.

## 2.6. Conclusions

Nous avons proposé ici différentes méthodologies pour prévoir le DLR, ainsi que différents paramétrages pour ces modèles. Nous avons pu constater, pour les différents modèles présentés, que les méthodes ensemblistes (GBRT et QRF) étaient celles qui présentaient les meilleures performances. Cela est principalement dû à la faible sensibilité de ces méthodologies face aux phénomènes de surapprentissage, qui sont importants pour deux raisons dans le cas de la prédiction du DLR.

La première raison est la nécessité d'utiliser un nombre de variable qui ne peut pas être faible. En effet, le DLR dépend de 4 variables météorologiques, et pour cette raison le nombre de paramètres à utiliser en entrée des modèles apparaît comme difficile à réduire vers un nombre faible.

La deuxième raison est que nous avons pu constater pour l'ensemble des modèles, de manière plus ou moins marquée, que les phénomènes de surapprentissage apparaissaient plus rapidement pour les prévisions à quantile bas que pour les prévisions à quantiles moyens. Or, dans le cas de la prédiction du DLR, les prévisions à bas quantile sont nécessaires en raison des exigences de sécurité des GRT.

Nous avons cité en introduction l'article [48], où un modèle MARS et un modèle QRF étaient tous deux mis en avant pour fournir des prévisions moyennes du DLR. Ici, on trouve de manière similaire des performances proches avec les indices du MAPE et du CRPS pour le modèle QLR, un modèle similaire au MARS, et le modèle QRF. Cependant, le QLR nécessite un nombre de variables significatif pour atteindre de telles performances, en particulier pour l'entraînement des prévisions à quantile moyen.

Pour des quantiles bas, le QLR doit être entraîné avec un nombre de variables faible, inférieur à 5, et on pourrait attendre un résultat similaire avec un modèle MARS adapté à la prédiction quantile, et ces deux modèles ne nous apparaissent alors pas adaptés à la prédiction à bas quantile. À l'inverse, le QRF peut fournir des prévisions pour de tels quantiles avec un nombre de variables élevé.

Pour ces raisons, nous considérons ici que les deux méthodes ensemblistes proposées sont les deux approches nous semblant les plus adaptées pour la suite de notre étude. Pour ces deux modèles, nous avons obtenu de meilleurs résultats avec le modèle QRF par rapport au modèle GBRT. Ce dernier modèle pourrait cependant à terme être réutilisé, dans un contexte où les fonctions objectif utilisées pour les prévisions DLR seraient redéfinies par rapport aux scores quantiles ici obtenus.

On soulignera ici que les trois autres modèles ne sont cependant pas à écarter pour des recherches futures. Même si nous ne les recommandons pas ici pour directement générer des prévisions DLR, leurs structures sont différentes de celles des méthodes ensemblistes, et cela pourrait permettre d'aider à dépasser des failles des QRF et GBRT. Par exemple, les QRF et GBRT ne sont pas capable de générer des combinaisons de variables, comme simplement une somme de différents paramètres. Les réseaux de neurones, écartés pour la génération de prévisions, seraient eux en mesure de générer de telles combinaisons. Ces nouvelles variables deviendraient alors des variables supplémentaires pouvant alimenter des méthodes ensemblistes et améliorer leurs performances, dans le cadre du développement

de processus de stacking. Ces hypothèses ne sont pas explorées plus en avant dans le cadre de cette thèse, et pourraient devenir l'objet de futurs travaux.

Tels que proposés ici, les modèles que nous retenons présentent tous les deux une faille, qui est leur incapacité à fournir des extrapolations pour des prévisions à très bas quantile. Là où les 3 autres modèles proposés peuvent fournir des prévisions inférieures aux valeurs de RTL<sub>R</sub> observées par le passé, pour des niveaux de probabilités tendant vers 0, ces deux modèles seront incapables de fournir des prévisions inférieures aux observations minimales faites dans l'échantillon d'entraînement. Pour cette raison, il est nécessaire d'apporter une modification à ces modèles pour fournir des prévisions à très bas quantiles satisfaisantes. Nous nous proposons d'aller dans ce sens dans le chapitre suivant.

# CHAPITRE 3

## Modélisation de la partie basse des distributions

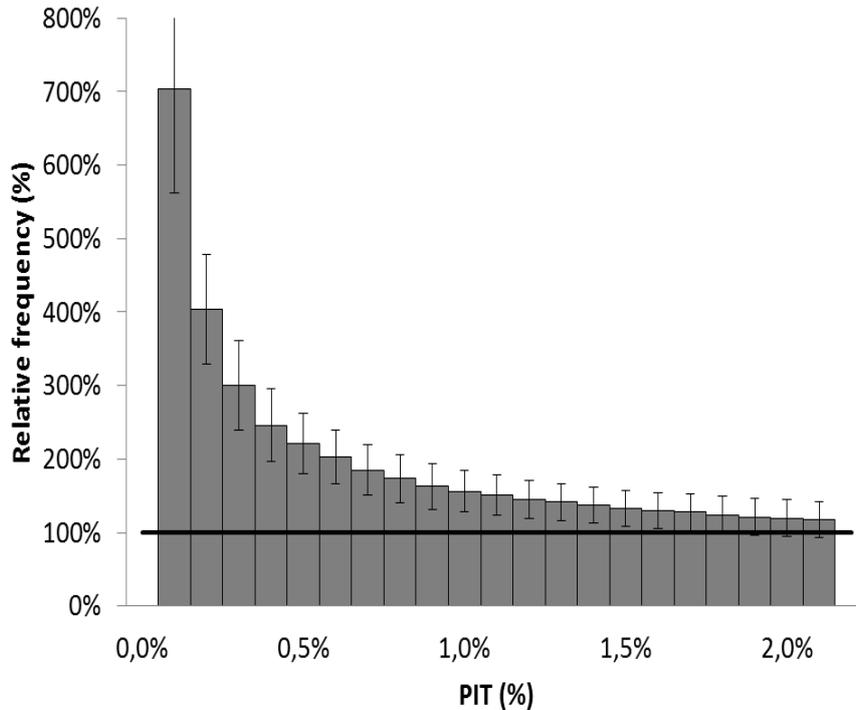
---

### 3.1. Introduction – Du besoin de prévisions extrêmes

Dans le chapitre 2, nous avons mis en avant deux méthodologies ensemblistes pour la prévision, le Gradient Boosting Regression Tree (GBRT) et le Quantile Regression Forest (QRF). On a pu constater sur les diagrammes de fiabilité que ces deux modèles montraient certaines difficultés à modéliser les quantiles bas (**Figure 2-19.B**), en particulier pour des prévisions à quantile 1%. Bien que cela n'ait pas été abordé, il est à noter que cette performance est encore plus marquée pour les quantiles que l'on pourrait qualifier d'extrêmes. En effet, les modèles GBRT et QRF sont relativement médiocres par rapport à leur capacité à prévoir ce type d'événements, en raison du peu d'observations associées à ce type de phénomène, et du fait que ces modèles sont incapables d'extrapoler vers une situation où le RTLR serait inférieur au minimum observé dans les échantillons d'apprentissage.

Pour illustrer cela, on a représenté sur la **Figure 3-1** le diagramme PIT pour des prévisions allant de 24 à 47 heures, faites à 12h00 pour 6 stations météorologiques différentes, avec un QRF et des fenêtres glissantes de 6 mois réactualisées tous les mois, un total de 47 150 prévisions étant alors considéré. On peut y voir que pour des prévisions quantiles à 0,1%, les prévisions supérieures aux observations sont 7 fois plus nombreuses que ce qui était attendu.

Au vu du cadre actuel de l'utilisation des prévisions DLR, cela n'est pas nécessairement problématique : tout d'abord, les gestionnaires de réseau utilisent fréquemment soit des prévisions pour des quantiles variant entre 1% et 10%, soit des valeurs de probabilité très supérieures aux valeurs évoquées plus haut. De plus, en règle générale, les prévisions sont modifiées pour assurer le respect de contraintes de sécurité, soit par la soustraction d'une marge de sécurité, soit avec l'établissement d'une limite maximale. Ainsi, le fait d'avoir des prévisions à bas quantile mal calibrées pose peu de problèmes, les mesures de sécurité ajoutées permettant de limiter les effets des erreurs de prévision.



**Figure 3-1.** Diagramme PIT créé de la même manière que ceux présentés sur la **Figure 2-19**, avec 6 stations différentes, fait pour des prévisions générées avec un modèle QRF, avec un changement d'échelle de manière à ne montrer l'évolution de la fiabilité que pour les quantiles allant de 0,1% à 2%.

Il faut cependant considérer que cet état de fait sera probablement amené à être modifié dans les années à venir, avec une utilisation plus poussée de prévisions probabilistes du DLR dans des méthodologies d'optimisation. Comme nous l'avons évoqué dans le chapitre 1, des premières études allant dans ce sens ont été présentées ces dernières années [60], [61], [96], dans lesquelles des optimisations stochastiques tenant compte du DLR pour l'optimisation du bien-être social sont présentées, avec des approches qui sont toutes neutres au risque et des prévisions RTLRL généralement associées à des niveaux de probabilité allant de 5% à 15%.

Nous pensons, et nous reviendrons sur ce point dans les chapitres suivants, qu'il faut considérer que les gestionnaires de réseau utiliseront des approches différentes, beaucoup plus averses au risque, cherchant à se rapprocher des risques similaires à ceux associés à l'utilisation de prévisions à très bas quantile ou au SLR. Il est en effet peu probable qu'un gestionnaire de réseau passe subitement d'une méthodologie conservatrice où des prévisions quantiles à 1% sont utilisées, à une approche neutre au risque où en moyenne on utilise des quantiles à 10%, ce qui augmente alors très fortement certains risques d'incident.

Dans ce contexte, si on considère que les gestionnaires de réseau chercheront à respecter des risques similaires à ceux associés à des prévisions à très bas quantiles fixes, il sera alors nécessaire de pouvoir modéliser de manière fiable des prévisions associées à des niveaux de probabilité inférieurs à 1%.

On peut alors considérer une densité de probabilité associée à la prévision du RTLRL comme découpée en trois parties :

- Des prévisions à quantiles moyens et hauts, supérieurs à 20%, qui n'ont qu'une utilité faible pour la prévision du RTLRL.

- Des prévisions à quantiles bas, allant de 1% à 20%, en pratique utilisées aujourd'hui pour des prévisions RTLRL.
- Des prévisions à quantiles très bas, pour des niveaux de probabilité variant entre 0% et 1%, dont l'utilité n'est pas démontrée dans la littérature.

Dans ce chapitre, on présentera le travail qui a été fait sur la modification de la modélisation des parties basses des distributions associées aux prévisions fournies par les modèles du chapitre 1. Deux méthodes ont été testées, une première basée sur les quantiles bas générés par les modèles initiaux et qui fournit par la suite des parties basses de distributions issues d'interpolations faites avec la théorie des valeurs extrêmes, et une deuxième méthode utilisant des échantillons d'apprentissage générés avec un *k-mean clustering* permettant d'obtenir des paramètres de queues de distribution exponentielles.

## 3.2. Modélisation de la partie basse à partir d'une seule prévision probabiliste

Pour la modélisation de la partie basse de la loi de distribution, nous avons utilisé dans un premier temps une méthodologie simple à mettre en œuvre. En effet, celle-ci peut directement être utilisée à partir d'une seule prévision probabiliste, sans nécessité d'autres informations. Cette approche est utilisée dans le domaine de la prévision énergétique, dans [124], où elle est utilisée pour optimiser la gestion de réserve avec des installations éoliennes.

A l'aide de prévisions à quantile bas, une interpolation est faite pour fournir des paramètres de queue de distribution, qui permettent alors d'avoir une modélisation des événements extrêmes. La forme de cette queue est définie à l'aide de la théorie des valeurs extrêmes, les prévisions percentiles respectant les caractéristiques nécessaires à l'application de cette théorie. Nous présentons ici succinctement cette méthodologie, ainsi que les résultats qui y sont associés.

### 3.2.1. Méthodologie

#### 3.2.1.1. Principe général – théorie des valeurs extrêmes

L'approche présentée dans cette section est inspirée des travaux présentés dans [125] et [126], et est basée sur l'utilisation de la théorie des valeurs extrêmes [127].

Cette théorie repose sur le théorème de la valeur extrême, ou théorème de Fisher-Tipett, qui énonce que, pour une suite d'observations  $Y_1, Y_2, \dots, Y_n$  que l'on réassigne en une liste  $Y_{1,n}, Y_{2,n}, \dots, Y_{n,n}$  telle que  $Y_{1,n} \leq Y_{2,n} \leq \dots \leq Y_{n,n}$ , il existe une paire de nombres réels  $(a_n, b_n)$  telle que  $a_n > 0$  et  $\lim_{n \rightarrow \infty} P\left(\frac{Y_{n,n} - b_n}{a_n} \leq x\right) = F(y)$ ,  $F$  étant une fonction de distribution non dégénérée, et la fonction de répartition associée étant une loi d'extremum généralisée (Gumbel, Fréchet ou Weibull):

$$\lim_{n \rightarrow \infty} P\left(\frac{Y_{n,n} - b_n}{a_n} \leq x\right) = \begin{cases} \exp\left(- (1 + \gamma y)^{-\frac{1}{\gamma}}\right) & \gamma \neq 0, 1 + \gamma y > 0 \\ \exp\left(- (1 + \gamma y)^{-\frac{1}{\gamma}}\right) & \gamma = 0 \end{cases} \quad (3-1)$$

L'utilisation de la théorie des valeurs extrêmes peut être utilisée sur deux types de jeux de données :

- Un premier correspondant à la compilation des valeurs maximales observées sur des séries de périodes. On pourrait par exemple considérer l'ensemble des valeurs maximales observées année après année. Cette méthode est qualifiée de « block maxima ».
- Un deuxième basé sur la sélection de l'ensemble des observations dont les valeurs dépassent un seuil. On parle ici de méthode « Peak Over Threshold » (POT).

On s'intéresse ici à la méthode POT, et pour un seuil  $u$ , on définit la loi de répartition associée au fait qu'une variable  $y$  dépasse ce seuil :

$$F_u(y) = P(Y - u \leq y | Y \geq u) \quad (3-2)$$

Il est montré dans [128] que l'équation (3-1) est vraie si et seulement si :

$$\lim_{u \rightarrow y^+} \sup_{0 < y < y^+ - u} |F_u(y) - G_{\gamma, 0, \sigma(u)}(y)| = 0 \quad (3-3)$$

où  $G_{\gamma, 0, \sigma(u)}(y)$  est une loi de répartition de Pareto généralisée :

$$G_{\gamma, 0, \sigma(u)}(y) = \begin{cases} \left(1 + \gamma \cdot \frac{y - \mu}{\sigma}\right)^{\frac{-1}{\gamma}}, & \gamma \neq 0 \\ \exp\left(-\frac{y - \mu}{\sigma}\right), & \gamma = 0 \end{cases} \quad (3-4)$$

### 3.2.1.2. Utilisation pour la prévision RTLR

On obtient alors une formule permettant de définir la distribution des variables à la valeur supérieure au seuil  $u$ . Considérant une suite de  $n$  observations indépendantes et identiquement distribuées, on pose  $Y_{1,n}, Y_{2,n}, \dots, Y_{n,n}$  tels que  $Y_{1,n} \leq Y_{2,n} \leq \dots \leq Y_{n,n}$ , et on définit  $u$  tel que  $u$  correspond au  $n$ -k<sup>e</sup> élément de la liste,  $u = Y_{n-k,n}$ .

A partir de (3-4), plusieurs estimateurs peuvent être définis, et on utilise ici un estimateur proposé dans [126], où l'estimation des prévisions quantiles  $\hat{y}_k^\tau$  est basée sur les formules (3-5) à (3-7) :

$$\hat{Y}_k^\tau = Y_{n-k,n} - \hat{a}_{n,k+1} \cdot \frac{\left(\frac{k+1}{(n+1) \cdot \tau}\right)^{\hat{\gamma}_{k+1}} - 1}{\hat{\gamma}_{k+1}} \quad (3-5)$$

$$\hat{a}_{n,k+1} = \frac{1}{k} \cdot \sum_{j=1}^k j \cdot (Y_{n-j+1,n} - Y_{n-j,n}) \cdot \left(\frac{j}{k+1}\right)^{\hat{\gamma}_{k+1}} \quad (3-6)$$

$$L(\hat{Y}_{k+1}^\tau, \mathbf{Y}) = \sum_{j=1}^{k-1} \left\{ \begin{array}{l} \log\left(\frac{1 - \left(\frac{j}{k+1}\right)^{\hat{\gamma}_{\tau, k+1}}}{\hat{Y}_{k+1}^\tau}\right) \\ - \frac{1 - \left(\frac{j}{k+1}\right)^{\hat{\gamma}_{\tau, k+1}}}{\hat{Y}_{k+1}^\tau} \cdot j \cdot \log\left(\frac{Y_{n-j+1,n} - Y_{n-k,n}}{Y_{n-j,n} - Y_{n-k,n}}\right) \end{array} \right\} \quad (3-7)$$

Il est difficile d'obtenir une suite d'observations respectant les critères associés à la théorie des valeurs extrêmes. Une alternative est alors proposée dans [129], où il est recommandé de considérer un ensemble de prévisions percentiles plutôt que des observations. A partir de ces prévisions percentiles, et en fixant

une valeur seuil, il est alors possible de remodeliser les quantiles inférieurs au quantile associé à la valeur seuil.

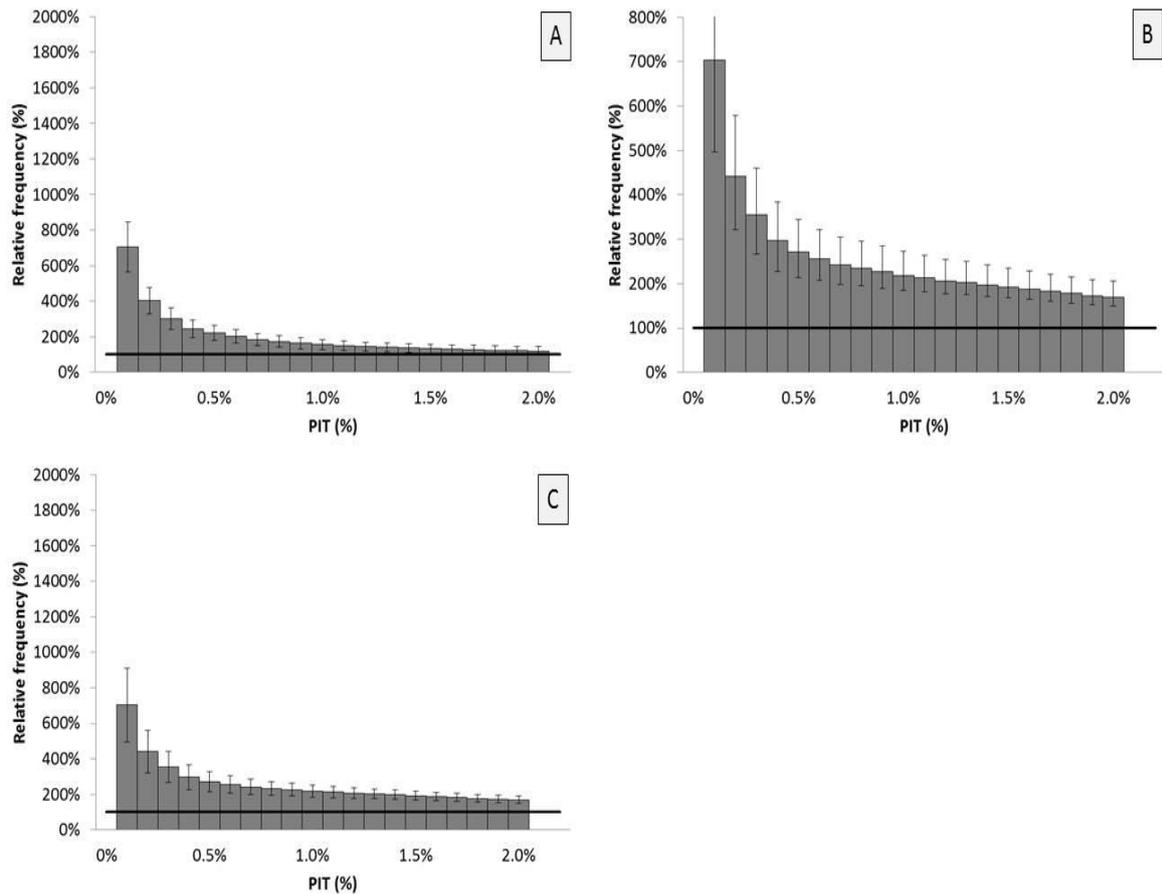
La génération de la liste  $Y_{1,n} \leq Y_{2,n} \leq \dots \leq Y_{n,n}$  est faite à partir des prévisions percentiles, et on utilise alors les prévisions percentiles en dessous d'un seuil donné. Cependant, on a vu précédemment qu'en général l'évaluation de la fiabilité à 2% était plus régulièrement correcte que la même évaluation à 1%. Dans ce contexte, on a alors utilisé 3 prévisions pour générer la queue de distribution, les prévisions quantiles à 2%, 4% et 6%,  $n$  étant alors égal à 48 et  $k$  à 3.

### 3.2.2. Résultats

Les résultats associés à cette méthodologie sont décevants dans une première approche. Le modèle est d'abord incapable de modifier une part non négligeable des prévisions, au vu de l'incapacité pour le modèle QRF de parfois fournir des prévisions à bas quantile différentes. On a en effet pour des fréquences variant entre 21% et 27%, fonction de la station météorologique considérée, des situations où des prévisions à bas quantiles ne peuvent pas être générées avec la méthode proposée.

De plus, en observant les prévisions qui sont modifiées, il apparaît que l'utilisation de la théorie des valeurs extrêmes comme dans [124] entraîne une dégradation importante des performances des modèles, en ce qui concerne les prévisions à très bas quantiles. On représente sur la **Figure 3-2** les fiabilités pour les quantiles allant de 0,1% à 2%, en fonction de l'utilisation ou non de la méthodologie proposée. Comme on peut le voir, sur la **Figure 3-2.A** et la **Figure 3-2.B**, où on représente la fiabilité pour des quantiles allant de 0,1% à 2%, en fonction de l'utilisation (B) ou non (A) de la méthodologie proposée, une dégradation importante de la fiabilité est occasionnée par l'utilisation de la méthodologie proposée.

Dans le cas ici présenté, cette dégradation est à imputer en grande partie aux situations où la partie basse de la distribution est modélisée avec une valeur de gamma négative, c'est-à-dire lorsque la modélisation de la partie basse de la distribution a une limite minimale. Ces situations représentent en moyenne 40% des prévisions faites. Lorsque l'on se contente de modéliser la partie basse avec seulement des valeurs de gamma positives, on observe une fiabilité beaucoup plus proche de celle observée avec le modèle initial, comme on le voit sur la **Figure 3-2.C**.



**Figure 3-2.** Diagrammes PIT créés de la même manière que ceux présentés sur la Figure 2-19, faits pour des prévisions générées avec un modèle QRF, avec une modification d'échelle de manière à ne montrer l'évolution de la fiabilité que pour les quantiles allant de 0,1% à 2%. Sur la Figure 3-2.A, le modèle utilisé est un QRF non modifié ; sur la Figure 3-2.B, le modèle utilisé est un QRF modifié avec la méthodologie proposée, indépendamment de la valeur de  $\gamma$  ; sur la Figure 3-2.C, le modèle utilisé est un QRF modifié avec la méthodologie proposée, les modifications n'étant faites que si  $\gamma > 0$ .

### 3.2.3. Discussion

Cette première méthodologie apparaît peu adaptée au modèle étudié, les résultats sur la fiabilité seule permettant de disqualifier cette approche. Au vu du faible nombre de points utilisés pour l'entraînement de chaque modèle, de l'ordre de 300, le QRF n'est que peu à même de générer des prévisions à bas quantile adaptées à la méthodologie que nous avons proposée, un quart des prévisions ne pouvant être utilisées avec les formules (3-5)-(3-7).

De plus, nous avons constaté que la génération de prévisions à bas quantile, soit entraîne une dégradation dans les cas où les queues de distribution étaient modélisées comme ayant une limite basse, soit dans le cas contraire n'a qu'un impact limité. Nous avons alors par la suite utilisé un autre type de modélisation pour la partie basse de la distribution.

### 3.3. Modélisation de la partie basse à partir d'un ensemble d'observations et de prévisions probabilistes

A la suite de la méthodologie basée sur l'utilisation de la théorie des valeurs extrêmes, dont les résultats étaient médiocres du point de vue de la fiabilité, nous avons utilisé une deuxième méthodologie basée sur des interpolations exponentielles.

#### 3.3.1. Interpolation exponentielle

Ici, on considère que la queue de la distribution, pour la partie basse de la distribution et pour un ensemble de prévisions données, a une forme de loi donnée. Deux formes ont été testées dans le cadre de ce travail. La première était basée sur la forme suivante, utilisée dans [129] :

$$F(Y, \rho) = \begin{cases} \rho \cdot \exp\left(\frac{\hat{Y}^{\tau_{\text{lim}}}}{Y} \cdot \ln\left(\frac{\tau_{\text{lim}}}{\rho}\right)\right), & 0 < Y \leq \hat{Y}^{\tau_{\text{lim}}} \\ 0, & Y > \hat{Y}^{\tau_{\text{lim}}} \end{cases} \quad (3-8)$$

où  $\hat{Y}^{\tau_{\text{lim}}}$  correspondait à une prévision quantile associée au quantile  $\tau_{\text{lim}}$  sous lequel la partie basse était modélisée. Cette forme était proposée dans [129] pour des prévisions de production d'EnR, et avait été développée de manière à ce qu'une probabilité nulle soit associée pour des valeurs de prévision inférieures à un seuil donné, ici 0 pour des prévisions éoliennes et solaires. Dans le cas du DLR, en raison de la difficulté à fixer ce seuil, nous avons par la suite préféré utiliser une interpolation exponentielle (3-9)-(3-10) :

$$f(Y, \rho) = \begin{cases} \tau_{\text{lim}} \cdot \rho \cdot \exp(\rho \cdot Y), & Y \leq \hat{Y}^{\tau_{\text{lim}}} \\ 0, & Y > \hat{Y}^{\tau_{\text{lim}}} \end{cases} \quad (3-9)$$

$$F(Y, \rho) = \begin{cases} \tau_{\text{lim}} \cdot \exp(\rho \cdot (Y - \hat{Y}^{\tau_{\text{lim}})}), & Y \leq \hat{Y}^{\tau_{\text{lim}}} \\ 0, & Y > \hat{Y}^{\tau_{\text{lim}}} \end{cases} \quad (3-10)$$

Cette approche peut se retrouver sur plusieurs types de prévisions, comme par exemple des prévisions de prix d'électricité [130] ou de productions de centrales éoliennes [124].

On considère que cette modélisation n'est valable qu'en-dessous d'un niveau de probabilité posé de manière arbitraire. Similairement aux études précédemment mentionnées, on pose ce niveau à 5%, et les prévisions quantiles allant de 0% à 5% auront ainsi leurs valeurs modifiées par rapport aux prévisions probabilistes initiales. On trouve alors la formule suivante pour les fonctions de densité et de probabilité cumulée :

$$f(Y, \rho) = \begin{cases} 0,05 \cdot \rho \cdot \exp(\rho \cdot (Y - \hat{Y}^{5\%})), & Y \leq \hat{Y}^{5\%} \\ 0, & Y > \hat{Y}^{5\%} \end{cases} \quad (3-11)$$

$$F(Y, \rho) = \begin{cases} 0,05 \cdot \exp(\rho \cdot (Y - \hat{Y}^{5\%})), & Y \leq \hat{Y}^{5\%} \\ 0, & Y > \hat{Y}^{5\%} \end{cases} \quad (3-12)$$

Pour le paramètre  $\rho$ , il est possible d'en obtenir une estimation  $\hat{\rho}$ , en écrivant la log-vraisemblance et sa dérivée en  $\rho$  :

$$\ln(L(Y_1, \dots, Y_N|\rho)) = N \cdot \ln(0,05) + N \cdot \ln(\rho) + \sum_{i=1}^N \rho \cdot (Y_i - \hat{Y}^{5\%}) \quad (3-13)$$

$$\frac{d \ln(L(Y_1, \dots, Y_N|\rho))}{d\rho} = \frac{N}{\rho} + \sum_{i=1}^N (Y_i - \hat{Y}^{5\%}) \quad (3-14)$$

Sachant que l'on a le maximum de vraisemblance lorsque  $\frac{d \ln(L(Y_1, \dots, Y_N|\rho))}{d\rho} = 0$ , on en déduit la valeur de  $\hat{\rho}$  :

$$\hat{\rho} = \frac{-N}{\sum_{i=1}^N (Y_i - \hat{Y}^{5\%})} \quad (3-15)$$

Considérant la valeur de  $\hat{\rho}$  et (3-12), il est alors possible d'obtenir de nouvelles prévisions quantiles, associées à cette méthode.

Dans une première approche, ce paramètre  $\rho$  peut être défini pour l'ensemble des prévisions. Une telle approche est par exemple utilisée dans [130]. Ici, on a préféré définir des valeurs de  $\hat{\rho}$  pour des clusters de prévision.

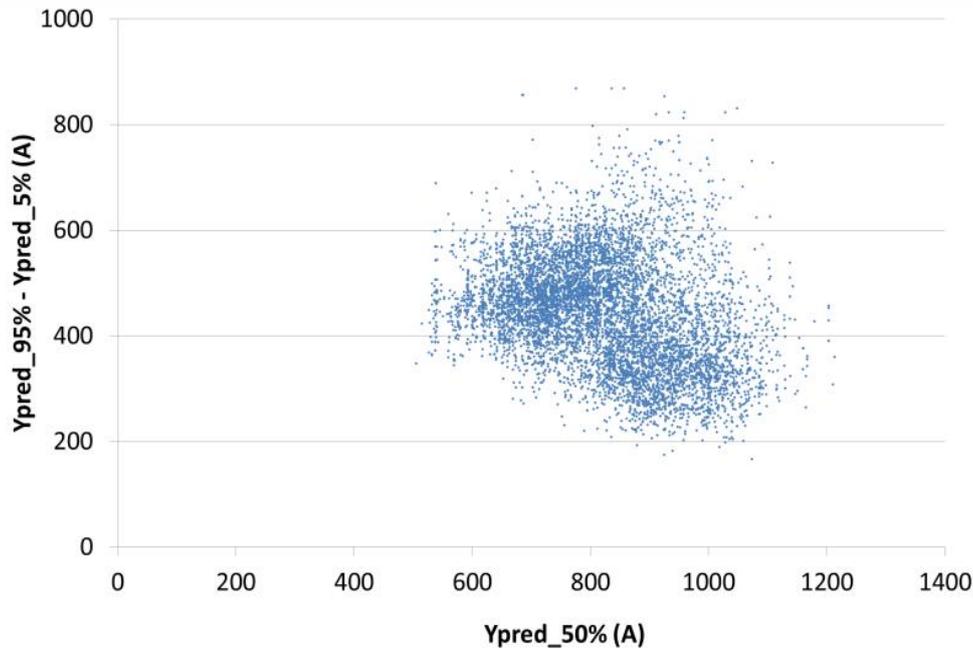
### 3.3.2. Partitionnement en k-moyennes

Dans [129], il est proposé de définir les paramètres  $\hat{\rho}$  comme dépendant de l'appartenance des prévisions à des clusters donnés. Ces clusters sont définis de manière simple, selon l'appartenance ou non de la prévision médiane  $\hat{Y}_{t+h|t}^{50\%}$  à des intervalles  $[a_i, a_{i+1}]$ . Les valeurs de  $a_i$  étant définies de telle manière que pour un ensemble de prévisions donné, chaque intervalle contient le même nombre de prévisions, à une observation près.

Cette approche nous apparaît plus difficile à justifier pour le RTLRL que pour des prévisions d'EnR. En effet, là où on peut admettre des écart-types associés à des prévisions relativement stables en fonction des prévisions médianes pour des prévisions de production d'énergie, ce n'est pas le cas pour le RTLRL, deux ensembles de variables très différents pouvant générer une même prévision médiane.

On pourrait illustrer cela en prenant l'exemple de deux prévisions médianes égales, associées soit à des prévisions de température et de vent faibles (une valeur élevée étant due à la prévision de la température faible, associée à un niveau d'incertitudes faibles), soit à des prévisions de température et de vent élevées (une valeur élevée étant due à la prévision de la vitesse du vent forte, associée à un niveau d'incertitude fort).

Ces ensembles de variables génèrent alors des prévisions médianes identiques, mais les prévisions à quantile bas seront, elles, très différentes. Pour illustrer cela, on représente sur la **Figure 3-3** un exemple d'évolution de la finesse de prévisions, ici représentée par la taille des intervalles à 90%, en fonction des valeurs des prévisions RTLRL médiane. On fera remarquer que cette figure illustre à nouveau le point illustré dans la section 2.5.2.2, qui est que pour la prévision du DLR, la finesse des intervalles décroît lorsque la prévision médiane croît.



**Figure 3-3.** Finesse des prévisions, ici représentée par la différence entre une prévision à 95% et une prévision à 5%, en fonction des valeurs des prévisions RTLR médianes pour la station 1, ce pour des horizons de prévision allant de 24 à 47 heures pour la période de l'année 2010.

Nous avons alors décidé d'utiliser deux quantiles  $\tau_1$  et  $\tau_2$  pour effectuer le clustering, là où un seul fixé à 50% était utilisé dans l'exemple cité. L'idée est de pouvoir avoir un clustering prenant en compte à la fois la prévision médiane et la finesse de la prévision probabiliste.

Pour effectuer le clustering, nous avons fait un partitionnement en  $k$ -moyennes (*k-mean clustering*), de manière à pouvoir aisément faire varier le nombre de clusters et les paramètres liés aux distances utilisées.

Considérant un ensemble de  $n$  observations de tuples de prévisions  $(\hat{Y}_m^{\tau_1}, \hat{Y}_m^{\tau_2})$ , le partitionnement en  $k$ -moyennes vise à partitionner l'ensemble des observations en une partition  $S$  de  $k$  ensembles, en cherchant à minimiser la distance entre les observations, ici des prévisions  $(\hat{Y}_m^{\tau_1}, \hat{Y}_m^{\tau_2})$ , de chaque ensemble et le barycentre de chaque ensemble,  $(\mu_i^{\hat{Y}_m^{\tau_1}}, \mu_i^{\hat{Y}_m^{\tau_2}})$ , aussi dit centroïde du cluster  $S_i$  (3-16) :

$$\min_S \sum_{i=1}^k \sum_{m \in S_i} \left( \hat{Y}_m^{\tau_1} - \mu_i^{\hat{Y}_m^{\tau_1}} \right)^2 + \left( \hat{Y}_m^{\tau_2} - \mu_i^{\hat{Y}_m^{\tau_2}} \right)^2 \quad (3-16)$$

Pour obtenir les clusters, nous avons utilisé la fonction *KMeans* du package python *sklearn* [131]. De plus, la résolution de ce problème, avec l'algorithme de Lloyd [132], peut donner des clusters différents en fonction des valeurs des centroïdes  $(\mu_{i,s1}^{\hat{Y}_m^{\tau_1}}, \mu_{i,s2}^{\hat{Y}_m^{\tau_2}})$ , définis lors de l'initialisation du problème, et à partir desquels l'algorithme va définir par la suite les clusters finaux. Pour limiter l'influence du choix aléatoire des premiers centroïdes, nous avons utilisé un nombre élevé d'initialisations différentes, ici 200, de manière à obtenir des résultats identiques pour deux mêmes opérations de clustering.

Pour faire les clusterings, nous avons testé plusieurs combinaisons différentes de couples pour la mise en place des clusters. Deux catégories étaient à différencier pour les couples, ceux générés à partir de quantiles fournissant une information sur l'ensemble de la prévision probabiliste (avec par exemple deux

quantiles symétriques, comme 5% et 95%) et ceux fournissant seulement des informations sur les quantiles bas (par exemple 5% et 10%).

### 3.3.2.1. Echantillon d'entraînement et de test

Dans le chapitre 2, nous avons travaillé à partir de deux ensembles d'observations pour générer les prévisions, un pour l'apprentissage de nos modèles de prévision et un pour la validation de ces modèles. Chacun de ses échantillons faisait la même taille, et correspondait à peu près à une année de collecte de données.

Pour l'entraînement de la méthodologie ici présentée, il est nécessaire de travailler à partir de l'échantillon d'entraînement évoqué, et cela considérant des prévisions réalistes qui auraient des caractéristiques statistiques similaires aux prévisions faites sur l'échantillon de validation.

Ces critères de similitudes entre les prévisions utilisées dans l'entraînement et en validation ne peuvent pas être respectés avec les prévisions telles qu'elles ont été initialement faites. Pour avoir des prévisions adaptées, on les générera alors par une méthode de "*k-fold cross-validation*": On divise l'échantillon d'entraînement en  $k$  échantillons, et on considère chacun de ces échantillons comme un échantillon test pour un modèle entraîné avec les  $(k-1)$  autre échantillons. Ici  $k$  est sélectionné de manière à ce que les échantillons correspondent à des périodes d'échantillonnage d'un mois.

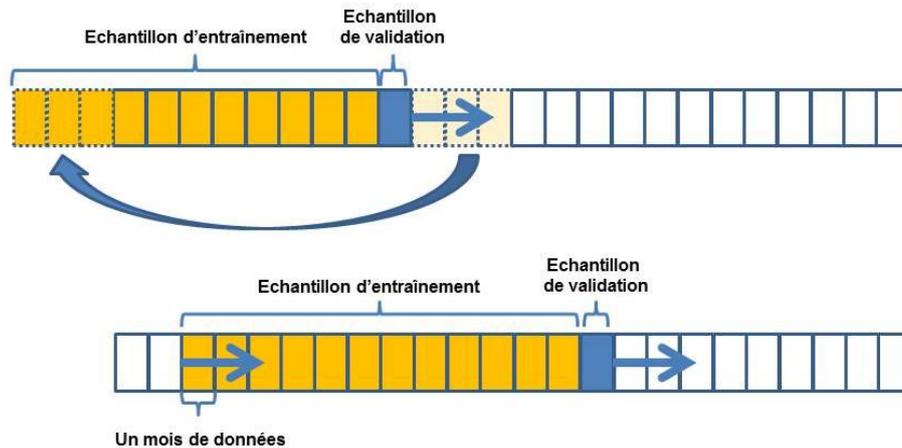
On concatène ensuite les prévisions obtenues et les observations pour obtenir un nouvel échantillon d'entraînement adapté pour faire la configuration des paramètres  $\rho$ .

Un problème associé à cette méthodologie est le faible nombre de données utilisées : considérant un an de données, on obtient normalement autour de 300 observations. Cela est suffisant pour observer des prévisions avec des quantiles inférieurs à 5%, mais ce n'est plus le cas lorsque l'on ajoute des clusters : pour un cas de dix clusters, en moyenne seulement près de deux observations correspondraient à des observations inférieures à des prévisions quantiles à 5%. On propose ici de travailler non plus sur des prévisions faites à un instant  $t$  pour un instant  $t+h$ , mais plutôt pour une concaténation d'ensembles de prévisions pour une liste d'horizons  $h+i$ , avec les valeurs de  $i$  appartenant à un intervalle donné. On définit ces ensembles d'horizons comme correspondant à des quarts de journée, avec les horizons de prévision suivants :

- De 24 heures à 29 heures.
- De 30 heures à 35 heures.
- De 36 heures à 41 heures.
- De 42 heures à 47 heures.

Chaque échantillon d'apprentissage est alors composé de près de 2000 observations, ce qui permet en moyenne d'avoir près de 100 observations inférieures à des prévisions quantiles à 5%.

Par la suite, les prévisions utilisées pour tester la méthode sont générées à partir de modèles entraînés sur des fenêtres glissantes, des échantillons correspondant à un an de données et réactualisés tous les mois, et testé sur des périodes de un mois. Cette fois, seuls les horizons  $t+h$  sont considérés pour les prévisions.



**Figure 3-4.** Schémas illustrant une méthode de k-validation croisée en haut, avec  $k=12$ , et une méthode d'entraînement avec fenêtre glissante en bas.

Sur la **Figure 3-5**, on illustre des clusters faits tel que proposé, pour des données issues de prévisions faites sur la station 1 et pour des horizons allant de 24 heures à 30 heure, ce pour 4 et 10 clusters. De plus, pour chaque cluster, on y ajoute la valeur du paramètre  $\rho$  y étant associée. Pour faciliter la lecture de ces graphiques, on précisera que plus les valeurs de  $\rho$  sont importantes, plus la queue de distribution « descendra » rapidement, et moins les prévisions à bas quantiles seront distantes des prévisions à quantile 5%. Comme on peut le voir sur ce cas précis, et on a pu retrouver cela sur l'ensemble des autres cas d'étude, il y a un impact sur les valeurs de  $\rho$  fonction du cluster d'origine. Cette distinction apparaît pour des cas où le nombre de cluster est faible (**Figure 3-5.A**), avec des variations allant du simple au double, et est marquée lorsque l'on travaille avec des nombres de clusters plus importants (**Figure 3-5.B**).

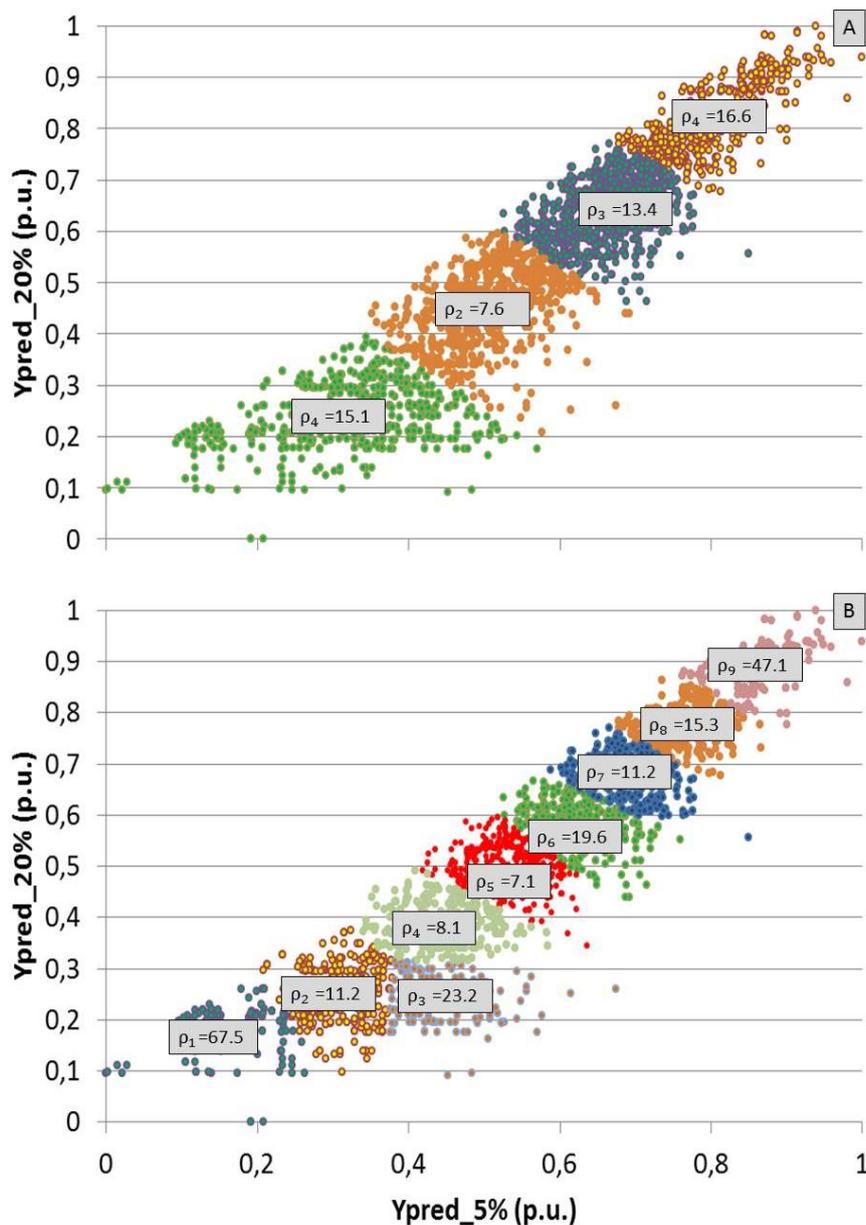
De manière générale, on a pu tirer quelques règles générales. Dans un premier temps, des valeurs de  $\rho$  importantes sont observées lorsque les valeurs de prévisions pour les quantiles à 5% et 20% sont toutes les deux faibles. On a observé pour l'ensemble des 24 cas de clustering (6 stations et 4 plages d'horizon) la valeur moyenne de ce paramètre sur le cluster associé aux prévisions respectant le plus ce critère (ici, celui au barycentre ayant la valeur d'abscisse la plus faible). On trouve alors une valeur médiane de  $\bar{\rho}$  de  $45,4 \text{ A}^{-1}$ , à comparer à la valeur de  $13,6 \text{ A}^{-1}$  obtenue dans un cas où un seul cluster est utilisé. Pour 23 des 24 cas considérés, la valeur de  $\rho$  associée au cluster bas est plus importante que la valeur de  $\rho$  associée au cas où il n'y a pas de clustering.

De plus, considérant une dizaine de clusters pour les partitionnements et ayant alors 240 clusters considérés au total (4 plages d'horizon \* 6 stations étudiées), on peut définir plusieurs paires de clusters, associés à des situations où les clusters se « chevauchent ». On peut illustrer cela sur la **Figure 3-5.B**, avec les clusters 3 et 4 dont les barycentres ont des abscisses proches, mais des ordonnées différentes. On définit ici ce que l'on qualifie de chevauchement lorsque les différences entre les abscisses ou les ordonnées de deux barycentres de clusters est inférieure à  $0,03\text{p.u.}$

Pour les chevauchements verticaux (les abscisses de deux barycentres sont proches), on trouve alors un total de 54 paires respectant ces critères. Pour 70% d'entre elles, la valeur de  $\rho$  est supérieure pour le cluster qui est « chevauché », c'est-à-dire dont la valeur de l'ordonnée du barycentre est la plus faible. Cette situation est observée sur la sur la **Figure 3-5.B**, avec le cluster 3 étant chevauché par le cluster 4, et ayant une valeur de  $\rho_3$  supérieure à celle de  $\rho_4$ . Pour 26% des clusters chevauchés, la valeur de  $\rho$  est

supérieure au double de la valeur du paramètre  $\rho$  trouvé pour le deuxième cluster, là où la situation inverse n'est observée que dans un seul cas. On retrouve alors une règle générale assez intuitive : pour une valeur de prévision à bas quantile donné, plus la valeur de la prévision à quantile supérieur sera élevée, plus la queue de distribution sera longue. On observe un phénomène similaire pour des chevauchements horizontaux, où les différences des valeurs d'ordonnée des barycentres ne diffèrent pas de plus de 0,3 p.u. : pour 84% des 25 paires observées, on a une queue moins longue lorsque les prévisions quantiles à 5% sont plus proches des prévisions à quantile supérieur.

Nous n'avons pas poussé plus loin l'investigation dans cette direction, mais ces deux derniers points nous permettent de visualiser les évolutions des définitions des paramètres  $\rho$  lorsque des structures de clusters différentes seraient utilisées.



**Figure 3-5.** Exemples de clustering faits sur des prévisions faites sur la station 1, pour des horizons de prévisions allant de 24 à 30 heures. 4 clusters sont considérés sur la **Figure 3-5.A** et 10 sur la **Figure 3-5.B**. Pour chaque cluster, on montre sur la figure la valeur de  $\rho$  obtenue.

### 3.3.3. Evaluation – fiabilité des prévisions à très bas quantile

Afin d'illustrer les effets des modifications proposées, on représente sur la **Figure 3-6** trois prévisions faites pour la même période avec un modèle QRF, mais dont la partie basse de la distribution n'est pas modifiée (**Figure 3-6.A**), est modifiée avec 4 clusters générées avec les quantiles (5%,10%) (**Figure 3-6.B**) et est modifiée avec 10 clusters générées avec les quantiles (5%,10%) (**Figure 3-6.C**).

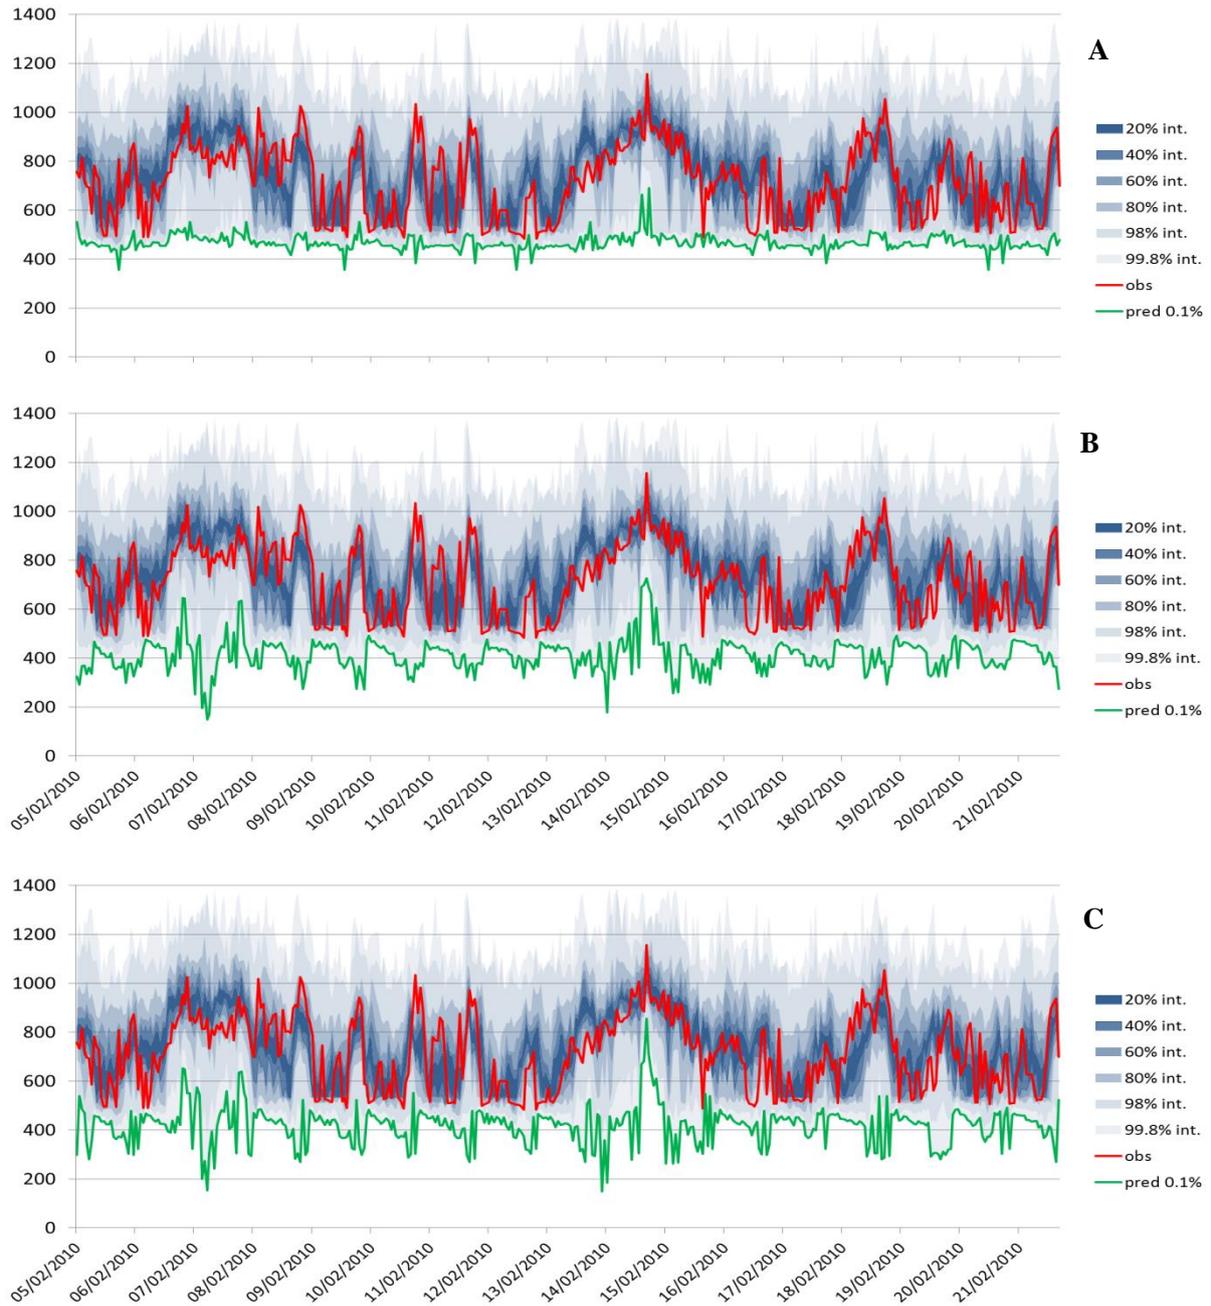
On représente sur la **Figure 3-7** l'évolution de la fiabilité relative des prévisions RTLQ quantile à 0,1%,0,2%, 0,5% et 1,0%, ce pour des modèles ayant été modifiés avec la méthodologie évoquée, avec des partitionnements faits avec un nombre de clusters variable et en fonction de couples de quantiles différents  $(\tau_1, \tau_2)$ . On peut constater que les fiabilités pour les bas quantiles sont fortement améliorées lorsque la méthodologie est utilisée, quel que soit le nombre de clusters et le couple de quantiles considérés.

On note aussi une amélioration de la fiabilité dès que le nombre de clusters est supérieur à 1. Par exemple, pour la fiabilité à 0,2%, on passe d'une fréquence relative de 210% avec 1 cluster à une fréquence relative variant entre 140% et 180% pour 4 clusters, même si une dégradation de la fiabilité est observée pour un nombre de clusters supérieur.

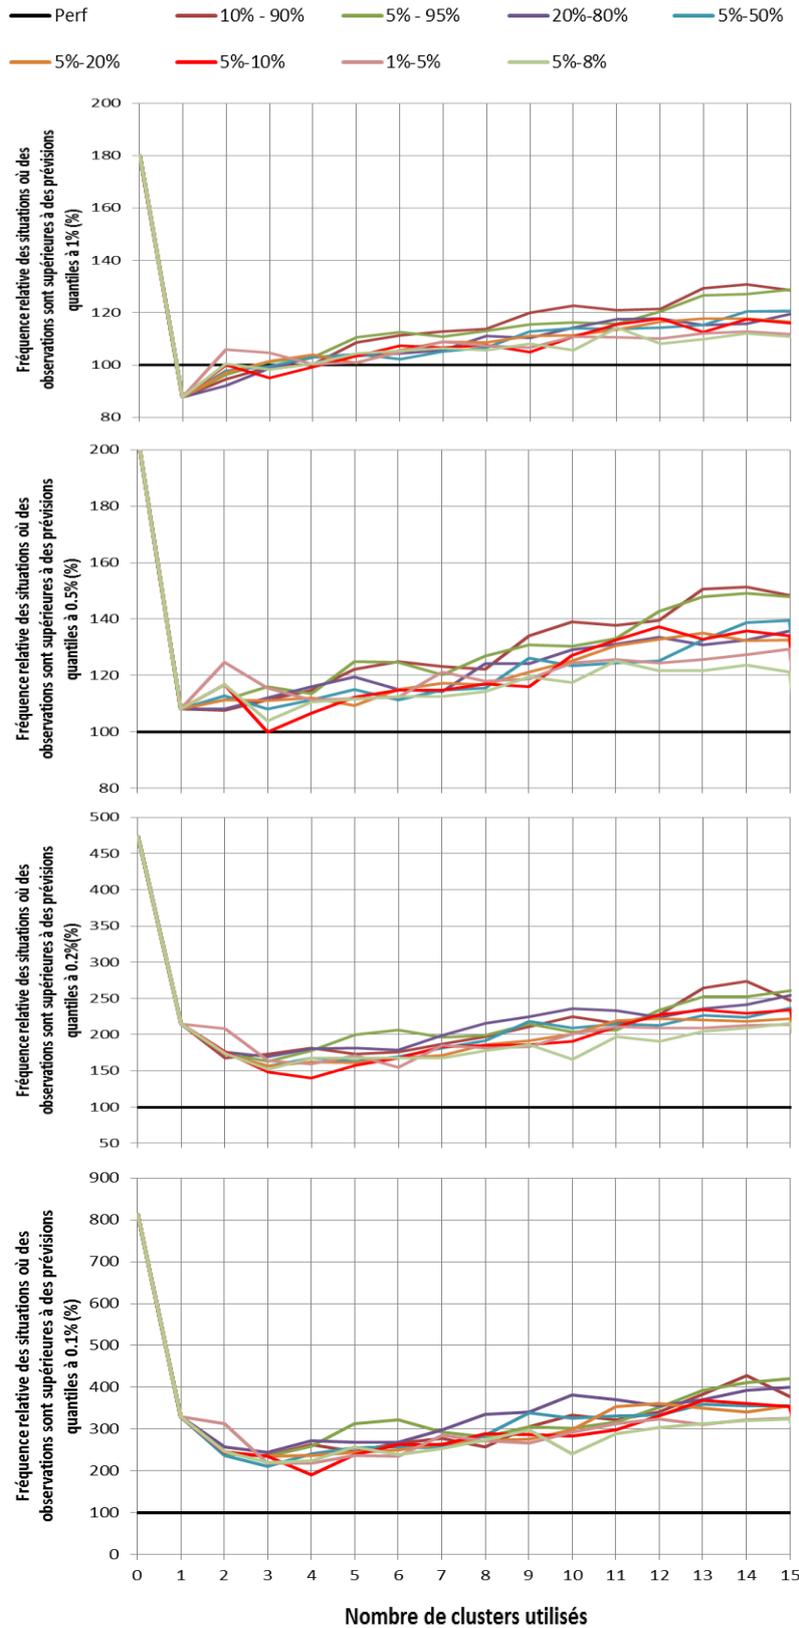
Plus les quantiles considérés sont élevés, plus les fréquences relatives observées sont proches des fréquences relatives idéales, une fréquence relative moyenne de 100% étant atteinte dans les cas des quantiles à 0,5% et 1,0%, là où on ne descend pas sous les valeurs de 140% pour le quantile 0,2% et 200% pour le quantile 0,1%.

On fera ici remarquer que si une fréquence relative moyenne de 111% était atteinte pour le quantile 1%, une telle valeur n'aurait pas pu permettre de conclure de la non-fiabilité des prévisions pour ce niveau de probabilité. En effet, comme cela était présenté dans la section 2.5.2.1, en considérant des lois binomiales, il est aisé de montrer que considérant ce nombre de prévisions et que si ces prévisions sont parfaitement fiables, il y a une probabilité de 1% que la fréquence relative moyenne soit supérieure à 111%. Pour le quantile 0.1% et pour des prévisions parfaitement fiables, la fréquence relative moyenne n'aurait que 1% de chance d'être supérieure à 130%. Une fréquence relative moyenne de 200% étant atteinte, on peut en déduire que même s'il y a une amélioration, les prévisions ne sont pas parfaitement fiables pour les quantiles 0.1%. En reprenant le même raisonnement, on peut poser en revanche qu'elles respectent une condition nécessaire pour être considérées comme parfaitement fiables pour un niveau de quantile de 0.2%. Pour ce cas d'étude, on peut alors poser que le procédé permet d'obtenir des résultats satisfaisants jusqu'à des niveaux de probabilité de 0,2%, même si des améliorations sont faites sur l'ensemble des niveaux de probabilités extrêmes.

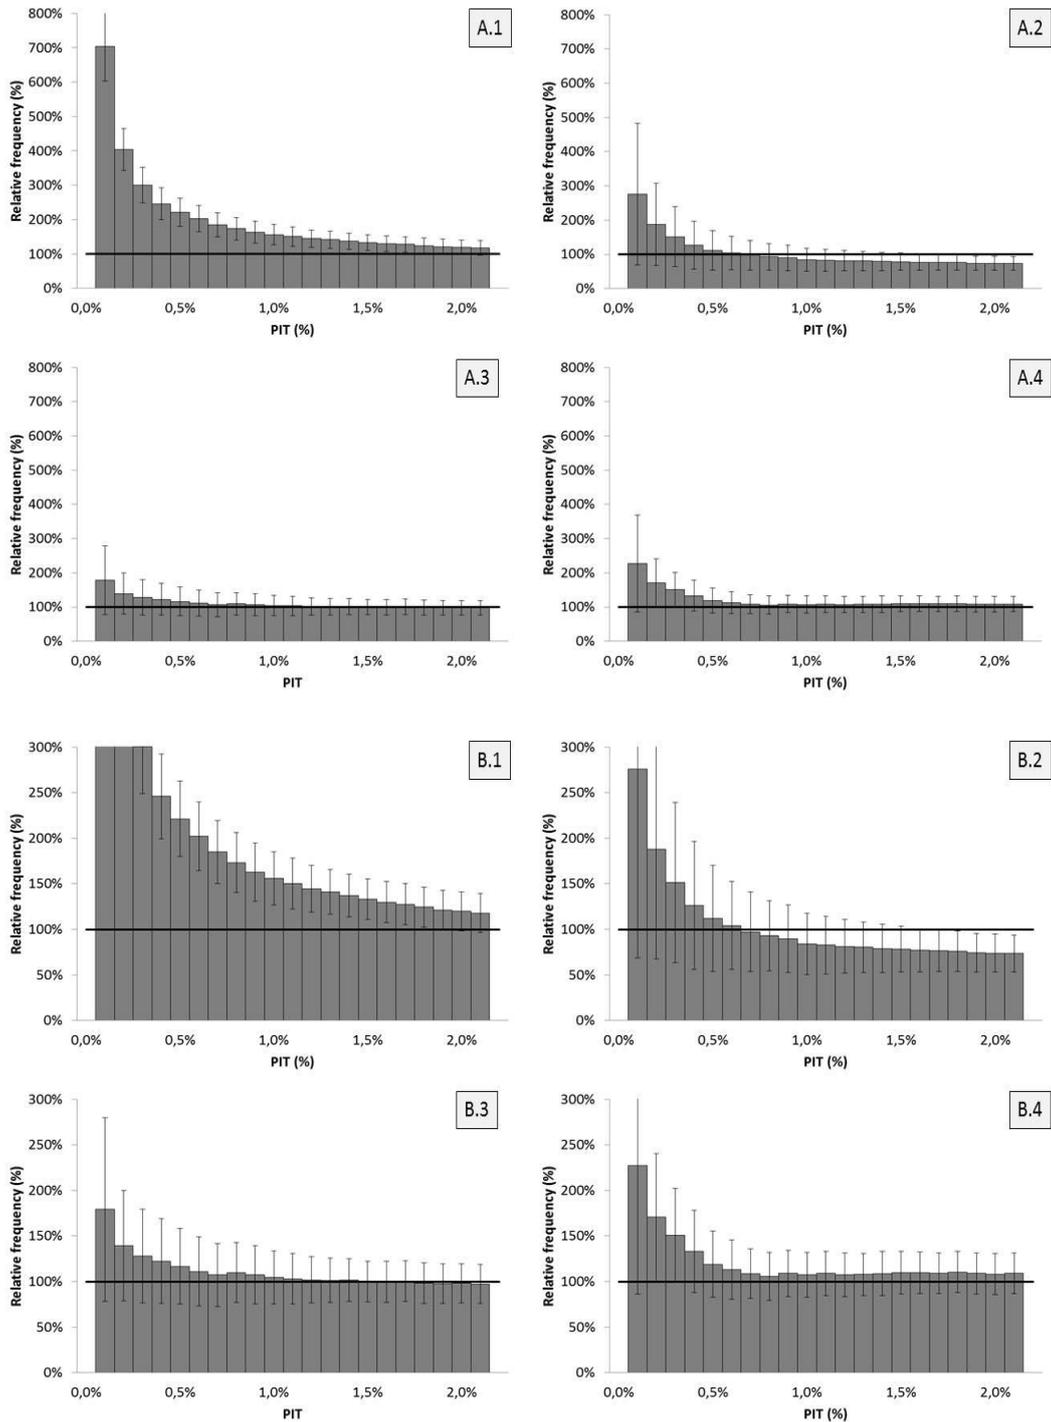
Parmi les combinaisons de cluster considérées, on reprend les deux catégories précédemment présentées, celle regroupant les tuples de quantiles donnant une information sur l'ensemble de la distribution, et celle regroupant les tuples de quantiles ne donnant des informations que sur les quantiles bas. Ici, les meilleures performances en termes de fiabilité sont observées pour des cas où les clustering appartiennent à la deuxième catégorie, les meilleures fiabilités étant observées pour les couples (1%,5%), (5%,10%) et (5%,20%). Pour la fiabilité, les meilleurs résultats sont observés avec un nombre de clusters relativement faible, ici 4. Pour illustrer l'amélioration des fiabilités pour les quantiles extrêmes apportés par l'utilisation des queues exponentielles, on représente les diagrammes PIT focalisés sur les quantiles allant de 0,1% à 2% sur la **Figure 3-8**.



**Figure 3-6.** Exemple de prévisions RTLR pour la station météo 1, fournies avec un QRF non modifié (A), un QRF modifié avec des queues exponentielles dont les paramètres sont associés à 5 clusters faits sur les couples de quantiles (5%,10%) (B) et un QRF modifié avec des queues exponentielles dont les paramètres sont associés à 10 clusters faits sur les couples de quantiles (5%,10%) (C).



**Figure 3-7.** Evolution de la fréquence relative d'événements où des prévisions RTLQ quantiles à 0,1%, 0,2%, 0,5% et 1,0% sont supérieures à des observations, moyennées pour les 6 stations météorologiques considérées et pour des horizons allant de 24 à 47 heures, pour des modèles de QRF dont les parties basses des distributions sont modifiées avec des interpolations linéaires aux paramètres fixés en fonction de l'appartenance à des clusters donnés. On définit le nombre de ces clusters de manière variable, allant de 1 à 15 clusters.

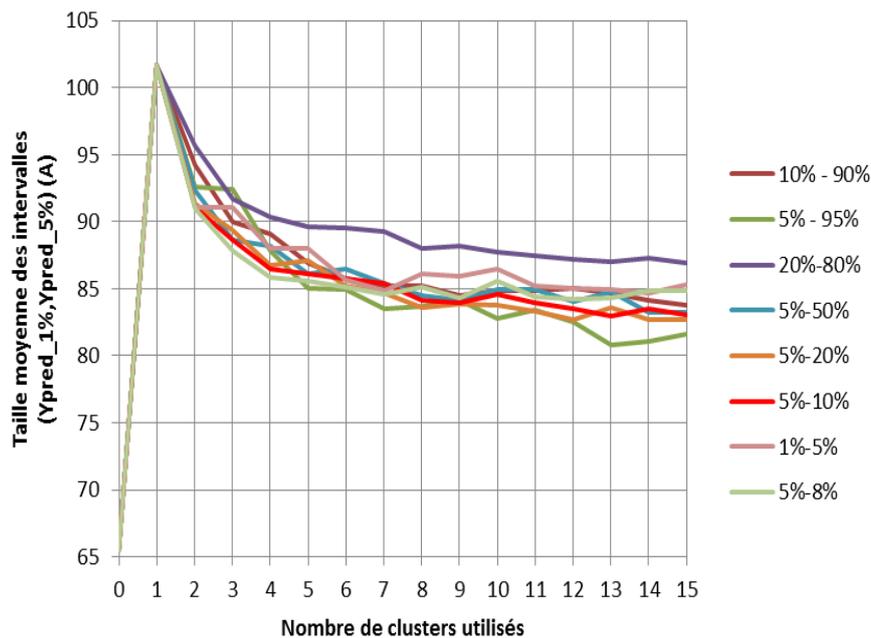


**Figure 3-8.** Diagrammes PIT créés de la même manière que ceux présentés sur la **Figure 2-19**, faits pour des prévisions générées avec un modèle QRF, avec un changement d'échelle de manière à ne montrer l'évolution de la fiabilité que pour les quantiles allant de 0,1% à 2%. Les figures A et B représentent les mêmes résultats, à l'exception de l'échelle sur l'axe des ordonnées qui est modifiée. Les figures 1 correspondent à un modèle n'ayant pas été modifié, les figures 2 à un modèle modifié mais où il n'y a pas eu de clustering et un seul paramètre  $\rho$  est considéré, les figures 3 un modèle où la méthodologie est utilisée avec 4 clusters, et les figures 4 un modèle où 10 clusters ont été utilisés.

### 3.3.4. Evaluation – finesse et scores quantiles

Par rapport à la méthode basée sur l'utilisation de la théorie des valeurs extrêmes, cette deuxième méthode fournit de biens meilleurs résultats du point de vue de la fiabilité. Cependant, la fiabilité n'est pas nécessairement suffisante pour évaluer les améliorations faites sur les prévisions à très bas quantile.

On étudie dans un premier temps l'évolution de la finesse des modèles de prévision améliorés avec les procédés évoqués. Sur la **Figure 3-9**, on représente l'évolution de la taille des intervalles ( $\hat{Y}_{t+h|t}^{1\%}$ ,  $\hat{Y}_{t+h|t}^{5\%}$ ), ce pour des modèles ayant été modifiés avec la méthodologie évoquée, avec des partitionnements faits avec un nombre de clusters variable et en fonction de couples de quantiles différents ( $\tau_1$ ,  $\tau_2$ ).



**Figure 3-9.** Evolution de la fréquence relative d'événements où des prévisions RTLR quantiles à 0,1%, 0,2%, 0,5% et 1,0% sont supérieures à des observations, moyennées pour les 6 stations météorologiques considérées et pour des horizons allant de 24 à 47 heures, pour des modèles de QRF dont les parties basses des distributions sont modifiées avec des interpolations linéaires aux paramètres fixés en fonction de l'appartenance à des clusters donnés. On définit le nombre de ces clusters de manière variable, allant de 1 à 15 clusters.

Là où les modifications que nous proposons permettaient de fournir des améliorations importantes pour la fiabilité, nous constatons ici qu'elles se font au coût d'une dégradation de la finesse, la taille des intervalles ( $\hat{Y}_{t+h|t}^{1\%}$ ,  $\hat{Y}_{t+h|t}^{5\%}$ ) augmentant en moyenne de près de 30%. Il est de plus difficile de trancher sur la question de la catégorie de tuple de quantile ( $\tau_1$ ,  $\tau_2$ ) permettant la dégradation la moins importante de la finesse, le tuple (5%,95%) fournissant par exemple les meilleures performances pour 10 clusters, et le tuple (5%,20%) fournissant les meilleures performances pour 11 clusters.

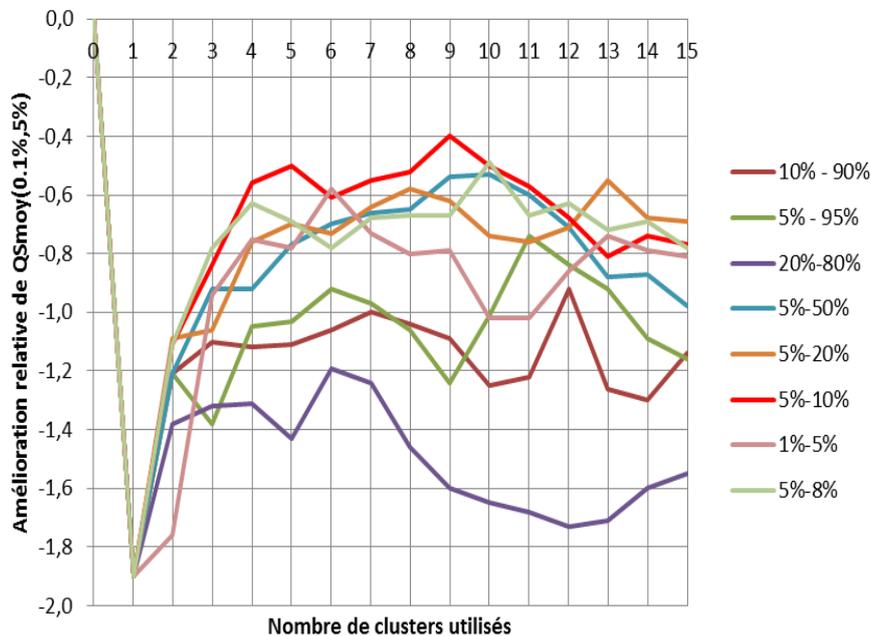
Dans l'optique de considérer un indice permettant d'évaluer simultanément la finesse et la fiabilité, on considère ici l'indice du score quantile comme dans le chapitre 2, en exploitant la somme des 50 scores quantiles pour les quantiles allant de 0,1% à 5,0%. Cet indice a de nombreuses failles pour l'application actuelle, le ratio entre les scores quantiles très bas et les scores quantiles plus élevés n'étant pas égal à 1 mais étant faible, ce qui donne ici un poids important aux scores quantiles des prévisions à quantile

proche de 5% par rapport aux scores quantiles des prévisions à quantiles inférieur à 1%. Nonobstant ces considérations, on considère cependant les résultats avec cet indice.

Sur la **Figure 3-10**, on montre l'évolution de  $QSmoy(0,1\%,5\%)$ , en considérant la mise en place de la méthodologie proposée, avec un nombre de clusters variables, faits pour des couples de quantile  $(\tau_1, \tau_2)$  différents.

Les variations, qui ne sont que des dégradations, apparaissent comme relativement faibles, de l'ordre de 1%. Cependant, cette variation est en grande partie due à des modifications des prévisions à très bas quantile, les prévisions pour des quantiles proches de 5% n'étant que peu modifiées. Les évaluations des prévisions pour ces quantiles très bas ayant peu d'impact sur l'indice final considéré, il est alors normal que des variations relatives faibles soient observées.

Comme avec les résultats sur la fiabilité, les meilleurs résultats sont obtenus lorsque les tuples de quantiles utilisés sont des quantiles bas tous deux inférieurs à 20%. En revanche, on constate que là où précédemment les meilleurs résultats pour la fiabilité étaient observés pour un nombre de 4 clusters, les maximums pour les scores quantiles sont ici observés pour un nombre de 9 clusters. Une question se pose alors ici du choix de la configuration pour l'utilisation des prévisions DLR, et nous reviendrons sur ce point dans le chapitre 5.



**Figure 3-10.** Evolution relative de la valeur moyenne des scores quantiles allant de 1% à 5%, moyennée pour les 6 stations météorologiques considérées et pour des horizons allant de 24 à 47 heures, pour des modèles de QRF dont les parties basses des distributions sont modifiées avec des interpolations linéaires aux paramètres fixés suivant l'appartenance à des clusters donnés. On définit le nombre de ces clusters de manière variable, allant de 1 à 15 clusters. Ces clusters sont définis en fonction de prévisions RTLR quantile pour des couples  $(\tau_1, \tau_2)$  différents.

## 3.4. Conclusions

Dans cette partie, nous nous sommes intéressés à la génération des prévisions RTL<sub>R</sub> à quantiles très bas. A partir d'un modèle de prévisions probabiliste du DLR que nous avons proposé dans le chapitre 2, nous avons testé deux méthodologies.

La première, basée sur l'utilisation de la théorie des valeurs extrêmes, est relativement décevante dans notre cas. Elle pourrait cependant à terme être réutilisée pour des modèles de prévisions aux caractéristiques différentes. On pourrait penser par exemple des modèles à très court terme qui ont une meilleure capacité à différencier les bas quantiles en raison des échantillons d'entraînement de taille très supérieure à ceux utilisés ici, ou alors à des modèles fournissant des densités de probabilité et n'étant pas en mesure de fournir deux prévisions identiques pour des quantiles bas différents.

La deuxième méthodologie que nous avons proposée, basée sur l'utilisation de clusters et d'interpolation exponentielle, nous a fourni de meilleurs résultats. Avec cette méthode, nous avons ainsi montré que des améliorations de la fiabilité pour les très bas quantiles importantes étaient possibles : pour un total de 47 150 observations, nous avons pu réussir à faire baisser la fréquence de dépassements des prévisions quantiles à 0,10% par les observations de 0,70% (330 dépassements) à une valeur de 0,18% (85 dépassements). En revanche ces améliorations étaient faites au prix d'une dégradation de la finesse ainsi que les indices du score quantile moyen évaluant les parties basses des distributions.

En première approche, au vu de la littérature, ce sacrifice de la finesse pour la fiabilité apparaîtrait comme acceptable : les prévisions DLR étant régulièrement utilisées avec des quantiles fixes, le critère de la fiabilité apparaît souvent comme le plus important, et la finesse est parfois ignorée dans les évaluations de modèles de prévision du DLR. On reprendra l'exemple de [73] et [72] où seule la fiabilité est utilisée pour faire une évaluation de modèles de prévision du DLR.

Nous montrerons cependant dans le chapitre 5 que cette réponse simple n'est pas satisfaisante, et que en fonction de la stratégie d'utilisation des prévisions DLR, qu'elle soit traditionnelle ou qu'elle appartienne au corpus des stratégies que nous avons développées, ces modifications peuvent avoir des conséquences économiques différentes.



# CHAPITRE 4

## Vers une sélection dynamique des Prévisions du Dynamic Line Rating

---

### 4.1. Introduction

Relativement à l'application des prévisions du DLR, deux caractéristiques se retrouvent régulièrement dans les méthodologies des gestionnaires de réseau.

La première caractéristique est le fait que des actions de recours en cas d'erreurs de prévision du DLR ne sont généralement pas considérées. On peut justifier l'absence de considérations sur des actions de correction en partant de la définition actuelle du SLR, dont il est recommandé de définir la valeur de manière à ce que des dépassements du SLR par le RTLTR ne puissent se produire qu'à un niveau de fréquence fixé [21].

Ce type de critère est respecté à la fois par un SLR calibré pour être en accord avec ce point mais aussi par des prévisions quantiles de RLTR, le quantile étant souvent fixé en accord avec les mêmes critères de sécurité que ceux associés au SLR. Nous pouvons résumer le raisonnement ainsi : si une prévision DLR quantile respecte les mêmes critères de sécurité que le SLR, ce critère étant la valeur de la fréquence des surestimations possibles, et qu'il n'y a pas besoin d'actions recours lorsque le SLR est supérieur au RTLTR, alors il n'y a pas besoin d'actions de recours en cas d'erreur de prévisions DLR.

A cela, on ajoutera que pour assurer une probabilité d'incidents faible, il est souvent proposé d'ajouter une modification des prévisions quantiles en amont de la définition de la prévision DLR dans le but de diminuer fortement les risques, ce qui réduit le besoin pour des actions de recours potentielles. On citera ici deux exemples :

- Dans [48], les auteurs utilisent des prévisions quantiles à 10%. Par la suite, une marge de sécurité est soustraite, correspondant à la magnitude de l'erreur maximale observée les 6 derniers mois.
- Dans une présentation faite par l'industriel producteur de câble Nexans [74], une méthodologie est présentée où des prévisions quantiles à 2,5% sont utilisées. Ces prévisions sont par la suite limitées par la définition d'un seuil maximal variable allant de 115% à 130% du SLR.

Ce n'est que récemment qu'il a été proposé dans la littérature de nouvelles approches où des actions de recours seraient mises en place pour des surestimations de la future observation du DLR, avec des

activations de réserve à la hausse et à la baisse des deux côtés de la ligne équipée du DLR. Pour rappel, l'état de l'art relatif à de telles méthodes a été présenté dans la section 1.6.2.

Une deuxième caractéristique de l'utilisation traditionnelle des prévisions DLR est le fait que les prévisions utilisées sont souvent des prévisions quantiles, le quantile étant fixé par le GRT. On rappellera ici l'éventail des quantiles arbitrairement sélectionnés pour des prévisions quantiles DLR utilisées :

- 1% dans [73].
- 2% dans [70]–[72].
- 2,5% dans [74], [75].
- 10% dans [48].
- 1%, 5% et 10% dans [51], [76].

Dans ce chapitre, nous avons souhaité poser une première piste de réflexion sur les avantages que l'on pourrait tirer d'une approche où des prévisions DLR optimales seraient utilisées. Cela serait fait à partir de prévisions probabilistes et de données de marché permettant de définir des gains potentiels et des coûts d'erreurs de prévision nécessitant des activations de réserve, un quantile optimal étant alors sélectionné pour la définition de chaque prévision DLR. Ce travail a été fait en utilisant des prévisions DLR réalistes et des données de marché historiques, et les résultats obtenus nous permettront de discuter des gains associés à la méthode proposée par rapport aux méthodologies initiales, avant d'en discuter les limites.

## 4.2. Choix et présentation du sujet d'étude

### 4.2.1. Choix du sujet d'étude

Le DLR est un sujet délicat à aborder en raison du fait que le besoin rempli par cette technologie n'est pas évident. En effet, contrairement à une ferme éolienne qui est généralement gérée de manière à maximiser le revenu qu'un producteur éolien peut en tirer, il est difficile de définir une forme générale de fonction objectif associée au DLR. Nous avons ainsi évoqué plusieurs utilisations possibles dans le chapitre 1 :

- Le DLR peut aider à améliorer la fiabilité du réseau électrique. Au vu de l'impact du DLR sur des indices de fiabilité du réseau comme l'EENS, on pourrait envisager des situations où des prévisions DLR seraient utilisées pour mettre en place des gestions de réseau visant à maximiser des niveaux de fiabilité.
- Le DLR peut faciliter l'introduction d'énergies éoliennes et solaires. Un producteur éolien connecté au réseau par une ligne potentiellement congestionnée pourrait, par exemple, prendre en compte des prévisions DLR pour le calcul de la quantité d'électricité mise en vente sur le marché spot. Une prévision DLR serait alors optimisée pour maximiser les revenus d'un producteur d'énergie.
- Le DLR peut augmenter la capacité d'échange entre deux pays, et permettre à des producteurs d'énergie peu couteuse d'avoir accès plus facilement à des nouveaux marchés.

Il était donc nécessaire de sélectionner une application du DLR sur laquelle définir une méthodologie d'application de prévision par rapport à ces différents points. Ici, nous avons choisi de travailler sur les échanges électriques aux frontières.

Ce choix était motivé par la volonté de travailler dans un premier temps à partir d'indices économiques, qui nous semblaient plus simples à aborder que des indices de risque dans une première approche. De plus, la technologie DLR étant encore principalement utilisée sur des réseaux haute tension, il nous apparaissait plus judicieux de travailler sur des problématiques d'échanges d'électricité aux frontières, associées à ces niveaux de tension, plutôt que sur des questions d'intégrations d'EnR, régulièrement associées à des niveaux de tension moyenne.

Pour visualiser l'intérêt du DLR dans ce cadre des échanges transfrontaliers que l'on considère, on rappellera que les coûts associés aux congestions limitant les échanges entre la France et ses voisins ont été en hausse ces dernières années, passant de 300 millions d'euros en 2012 [12] à 475 millions d'euros en 2015 [2], représentant alors près de 10% de l'ensemble des revenus de RTE. Même si une part significative de ces coûts est due à des contraintes de stabilité et non des contraintes thermiques, nous jugeons ce cadre d'utilisation comme satisfaisant pour fournir des débouchés à l'utilisation de prévisions DLR.

#### 4.2.2. Cadre relatif à la définition de la capacité d'échange transfrontalière

On définit la capacité d'échange totale (TTC (MW) pour *Total Trading Capacity*) d'un marché d'électricité 1 vers un marché 2 comme la quantité d'énergie électrique maximale qui peut être transférée du marché 1 vers le marché 2 en respectant l'ensemble des contraintes de réseau électrique.

Cette TTC est définie à partir de scénarios définis par les gestionnaires de réseau des deux marchés, ainsi que parfois par des acteurs d'autres marchés qui par leurs actions peuvent générer des flux à la frontière considérée. On pourrait ici prendre en exemple le fait que certains échanges décidés entre l'Allemagne et la France peuvent générer des flux de puissance à la frontière franco-belge qui peuvent affecter la valeur de la TTC pour cette frontière, ces flux étant qualifiés de *loop flows*.

La TTC est calculée avec la résolution de problèmes de flux de puissance. Dans [133], ce problème est décrit comme la maximisation de la puissance générée dans la zone 1, ce qui revient à résoudre un *optimal power flow* pour un scénario de consommation donné en considérant des coûts de -1€/MWh dans la zone 1 et de 0€/MWh dans la zone 2. Dans la résolution de tels problèmes, le critère N-1 est respecté, soit en prenant en compte des incidents possibles sur l'ensemble des générateurs du réseau et des lignes électriques comme cela est par exemple présenté dans [134], soit en ne prenant en compte que des lignes électriques, comme c'est le cas dans [53] où le DLR est étudié comme technologie pouvant impacter les valeurs de TTC.

Par la suite, pour des raisons de sécurité, une marge de sécurité, souvent fixe est soustraite à la valeur de la TTC (la *Transmission Reliability Margin*, TRM), le gestionnaire de réseau Elia fixant par exemple une TRM de 250MW pour chacune de ses frontières [135]. La valeur obtenue après cette soustraction est appelée capacité d'échange disponible (ATC pour *Available Trading Capacity*)

Cette ATC est définie pour quatre périodes données [135] :

- L'ATC annuelle, valable pour une année entière, et respectant un ensemble de scénarios critiques pouvant se produire sur une année.
- L'ATC mensuelle, valable pour un mois entier, et respectant un ensemble de scénarios critiques pouvant se produire sur un mois.
- Une valeur d'ATC définie en J-1.
- Une valeur d'ATC pour le marché infra-journalier.

Au fur et à mesure que l'échéance de résolution des échanges s'approche, l'incertitude baisse et les scénarios utilisés pour définir l'ATC deviennent de moins en moins critiques. Il est alors possible pour le GRT d'augmenter l'ATC proposée.

Si la demande d'ATC est inférieure à l'ATC proposée par le GRT, les acteurs souhaitant échanger de l'électricité à la frontière peuvent disposer gratuitement de l'ATC pour procéder à leurs échanges.

S'il y a congestion, l'ATC est distribuée entre les différents acteurs au travers de mécanismes de marché, les acteurs payant ce qu'on appelle une rente de congestion auprès des GRT.

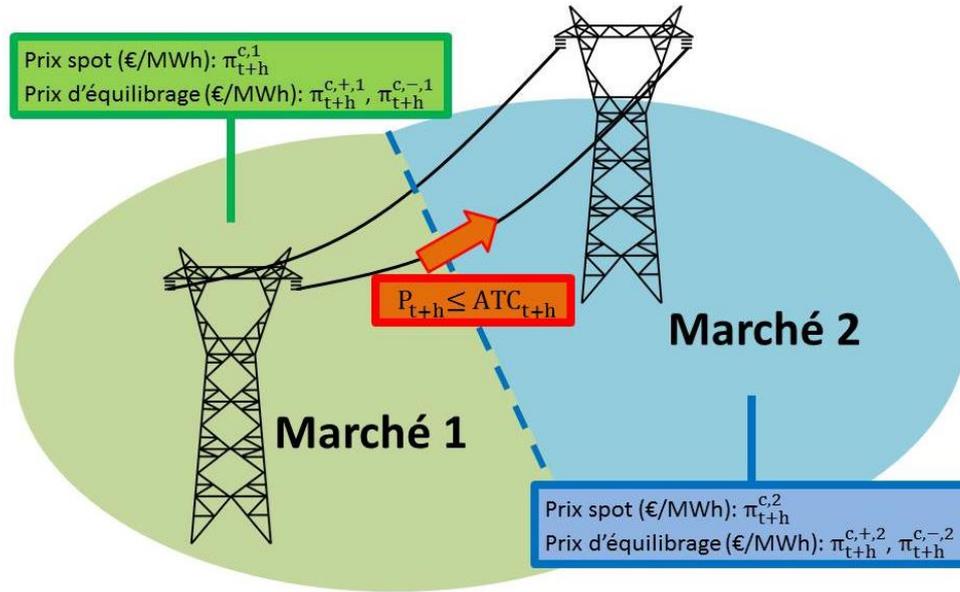
Dans ce chapitre, nous avons considéré le problème de la définition de l'ATC en J-1, en accord avec des prévisions DLR. De manière similaire à ce qui est fait pour des producteurs éoliens [77] cherchant à maximiser leurs revenus en prenant en compte des données de marchés et des prévisions probabilistes de production, nous nous sommes intéressés à une approche similaire pour des gestionnaires de réseau cherchant à maximiser une fonction objectif en accord avec des prévisions DLR.

## 4.3. Méthodologie

### 4.3.1. Description du sujet d'étude

On considère deux marchés d'électricité distincts reliés par un ensemble de lignes pouvant transporter une quantité de puissance donnée, la TTC, que l'on pose ici égale à l'ATC et à la NTC utilisées en pratique ( $TTC=NTC=ATC$ ), et dont on considère qu'elle est parfaitement proportionnelle à la valeur du DLR ( $NTC_{t+h}^* = R_{DLR/TTC} \cdot DLR_{t+h}$ , avec  $R_{DLR/TTC}$  une constante).

Pour les deux marchés, on définit des prix spots  $\pi_{t+h}^{c,1}$  et  $\pi_{t+h}^{c,2}$ , les prix de l'électricité sur le marché J-1 avant application du DLR pour la définition d'une nouvelle valeur de TTC, ainsi que des prix d'activation de réserve à la hausse et à la baisse  $\pi_{t+h}^{c,+1}$ ,  $\pi_{t+h}^{c,-1}$ ,  $\pi_{t+h}^{c,+2}$  et  $\pi_{t+h}^{c,-2}$  (€/MWh) qui sont définis pour le moment de la réalisation de la prévision de la TTC (**Figure 4-1**).



**Figure 4-1.** Schéma des deux marchés d'électricité considérés.

Considérant que les deux coûts sont tels que  $\pi_{t+h}^{c,1} \geq \pi_{t+h}^{c,2}$ , de nouveaux prix spot  $\pi_{t+h}^{c,1,\delta_{NTC}^+}$  et  $\pi_{t+h}^{c,2,\delta_{NTC}^+}$  pourraient être définis si la NTC augmentait de  $\delta_{NTC}^+$ , tels que :

$$\pi_{t+h}^{c,1} \geq \pi_{t+h}^{c,1,\delta_{NTC}^+} \geq \pi_{t+h}^{c,2,\delta_{NTC}^+} \geq \pi_{t+h}^{c,2} \quad (4-1)$$

L'obtention des nouveaux prix spot est difficile à définir. Dans [45], lorsque le DLR permet une augmentation de la NTC, l'auteur propose une approche simplifiée pour fixer les évolutions des prix et étudier l'impact du DLR :

$$\pi_{t+h}^{c,2} = \pi_{t+h}^{c,2,\delta_{NTC}^+} \quad (4-2)$$

$$\pi_{t+h}^{c,1,\delta_{NTC}^+} = \pi_{t+h}^{c,1} + \frac{\pi_{t+h}^{c,2} - \pi_{t+h}^{c,1}}{2} \quad (4-3)$$

Dans notre cas, nous avons émis l'hypothèse que ces coûts n'étaient pas modifiés lors de l'évolution de la NTC, considérant que ces évolutions étaient limitées (4-4)-(4-5) :

$$\pi_{t+h}^{c,2,\delta_{NTC}^+} = \pi_{t+h}^{c,2} \quad (4-4)$$

$$\pi_{t+h}^{c,1,\delta_{NTC}^+} = \pi_{t+h}^{c,1} \quad (4-5)$$

On rappellera ici quelques points permettant de justifier cette hypothèse forte. Tout d'abord, même si on travaille sur des prévisions DLR non modifiées, il est probable que les prévisions DLR seront limitées dans leurs variations pour limiter les risques de surestimations ayant une magnitude importante, et leur impact sur les prix sera alors réduit.

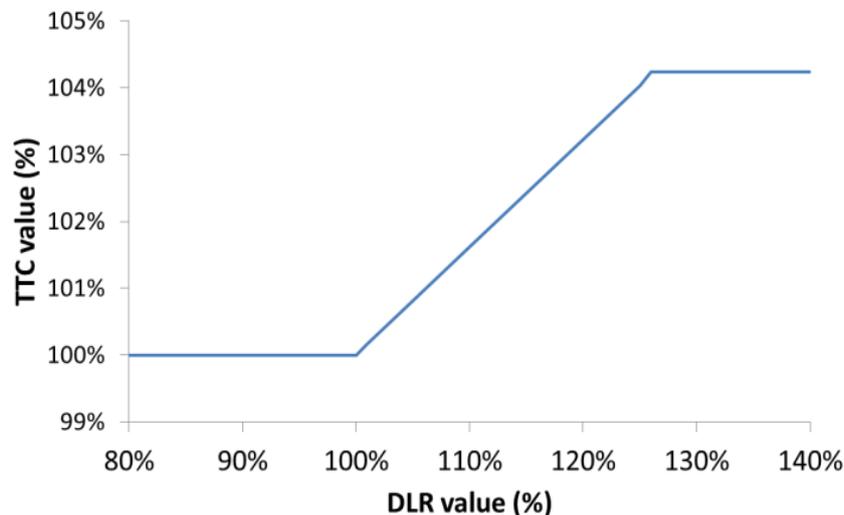
Il faut aussi ajouter qu'en plus de limites posées par le gestionnaire de réseau pour les variations du DLR, il y a des limites physiques qui limitent les bénéfices des valeurs de DLR élevées. Nous avons déjà évoqué dans la section 1.2.1 le fait que la nature de la contrainte dans une ligne électrique pouvait changer lorsque la contrainte thermique devenait moins contraignante, au profit de contraintes de chutes de tension ou de stabilité.

On soulignera aussi qu'à partir d'un certain seuil, l'augmentation de l'ampacité d'une ligne congestionnée ne permet plus d'augmenter la TTC, car une nouvelle ligne du réseau se retrouvera congestionnée, les réseaux HTB étant opérés dans des structures maillées et non radiales.

Pour illustrer ce deuxième point, nous avons mesuré l'influence de l'ampacité d'une ligne congestionnée sur la TTC dans un réseau IEEE à 24 nœuds, le même problème d'optimisation que celui proposé dans [133] étant résolu. La TTC de ce réseau est limitée par l'ampacité d'une ligne donnée, et on représente sur la **Figure 4-2** l'évolution de cette TTC lorsque l'ampacité de la ligne augmente. Deux points sont à noter :

- La TTC n'évolue pas avec un ratio de 1 pour 1 par rapport à l'ampacité des lignes congestionnées. Ici, une augmentation de l'ampacité des lignes congestionnées de 25% par rapport au SLR ne permet une augmentation de la TTC que de 4,5%.
- A partir de 104,5%, la TTC n'évolue plus avec l'ampacité de la ligne. A ce moment, une nouvelle ligne devient congestionnée, et des augmentations de DLR supérieures à 125% du SLR n'apportent plus de bénéfices.

Ces deux points contredisent les hypothèses que nous avons définies en introduction, le fait que la NTC est proportionnelle au DLR avec un rapport de 1 pour 1 et qu'elle peut croître indéfiniment avec le DLR, et cela justifiera par la suite en partie le travail présenté dans le chapitre 5.



**Figure 4-2.** Exemple de l'évolution de la TTC avec l'ampacité d'une ligne initialement congestionnée, pour la cas proposé dans [133]. A noter que pour une valeur de DLR inférieure à 100%, on a considéré sur cette figure que la valeur du SLR était alors utilisée en pratique sur la ligne.

### 4.3.2. Définition de la fonction objectif

Pour définir l'objectif recherché lors de la définition d'une prévision DLR optimale, une première approche serait de considérer le gestionnaire de réseau comme un acteur cherchant à maximiser ses revenus, mais une telle hypothèse n'est cependant pas conforme à la réalité. En effet, un gestionnaire de réseau ayant une telle approche serait dépendant de la différence de prix d'électricité entre les marchés connectés pour pouvoir réussir à obtenir un revenu, et pourrait alors être amené à délibérément congestionner ses lignes pour pouvoir améliorer ses revenus.

Or, on constate aujourd'hui que l'objectif des gestionnaires de connexions transfrontalières est de réussir à amener la rente de congestion à une valeur faible ou nulle, et donc à réduire voire annuler le revenu de la rente de congestion. Ainsi, on peut lire dans le rapport de la Commission de Régulation de l'Énergie [2] :

*“La rente de congestion perçue par RTE est la conséquence directe du nombre d'interconnexions de la France et de leur importance en termes de volumes échangés. Elle traduit également le niveau élevé des différentiels de prix entre le marché français et celui de plusieurs de ses voisins. C'est fort de ce constat que le gestionnaire de réseau français RTE, soutenu par la CRE, s'est engagé dans des investissements visant à augmenter les capacités mises à disposition du marché sur les interconnexions où cela est pertinent”.*

Dans les articles évoqués dans la section 1.6.2, les auteurs proposent des optimisations stochastiques prenant le DLR en compte. L'objectif est la minimisation des coûts de production, considérant à la fois les coûts de production prévus en cas de prévisions DLR parfaites, et les coûts associés à des activations de réserve. Dans un contexte de demande inélastique au prix, on peut considérer cette approche comme une maximisation du bien-être social (SW), et nous proposons de reprendre une telle approche.

L'objectif est alors de maximiser la somme de deux composantes :

- Un premier terme de bénéfice associé à la réduction des coûts de production  $\Delta_{SW}^+$  (€), permise par l'augmentation de la NTC de la valeur  $NTC^{SLR}$  vers une valeur mise en vente par le GRT de  $NTC_{t+h}^c$ . Si les derniers entrants pour des niveaux de puissance ( $NTC_{t+h}^c - NTC^{SLR}$ ) sur les marché 1 et 2 produisent de l'électricité à des prix  $\pi_{t+h}^{c,1}$  et  $\pi_{t+h}^{c,2}$  indépendants de la NTC, on peut écrire la variation des coûts de production comme suit (4-6) :

$$\Delta_{SW}^+ = (NTC_{t+h}^c - NTC^{SLR}) \cdot |\pi_{t+h}^{c,1} - \pi_{t+h}^{c,2}| \quad (4-6)$$

- Un deuxième terme de coût en cas d'erreur de prévision du DLR  $\Delta_{SW}^-$  (€). Si le gestionnaire de réseau doit abaisser la NTC de la valeur mise en vente sur le marché spot vers une valeur observée  $NTC_{t+h}^*$ , tel que  $NTC_{t+h}^* < NTC_{t+h}^c$ , et si l'on considère les coûts d'équilibrage inchangés, on peut poser que les coûts d'équilibrage seront associés à des activations de réserve (4-7) :

$$\Delta_{SW}^- = \begin{cases} 0 & \text{si } NTC_{t+h}^* \geq NTC_{t+h}^c \\ (\pi_{t+h}^{c,+1} + \pi_{t+h}^{c,-2}) \cdot (NTC_{t+h}^* - NTC_{t+h}^c) & \text{si } NTC_{t+h}^* < NTC_{t+h}^c \text{ et } \pi_{t+h}^{c,1} \geq \pi_{t+h}^{c,2} \\ (\pi_{t+h}^{c,+2} + \pi_{t+h}^{c,-1}) \cdot (NTC_{t+h}^* - NTC_{t+h}^c) & \text{si } NTC_{t+h}^* < NTC_{t+h}^c \text{ et } \pi_{t+h}^{c,1} < \pi_{t+h}^{c,2} \end{cases} \quad (4-7)$$

Considérant ces deux termes, on trouve la fonction suivante à maximiser (4-8) :

$$SW = \begin{cases} (NTC_{t+h}^c) \cdot (\pi_{t+h}^{c,1} - \pi_{t+h}^{c,2}) + \Delta_{SW}^- & \text{si } \pi_{t+h}^{c,+1} \geq \pi_{t+h}^{c,-2} \\ (NTC_{t+h}^c) \cdot (\pi_{t+h}^{c,2} - \pi_{t+h}^{c,1}) + \Delta_{SW}^- & \text{si } \pi_{t+h}^{c,+1} < \pi_{t+h}^{c,-2} \end{cases} \quad (4-8)$$

Après développement de cette fonction, on trouve que celle-ci a une forme de fonction de perte Pinball, et on peut directement en tirer la formule d'un quantile optimal  $\tau_{t+h}^{NTC}$  (4-9) :

$$\tau_{t+h}^{NTC} = \begin{cases} \frac{\pi_{t+h}^{c,1} - \pi_{t+h}^{c,2}}{(\pi_{t+h}^{c,+1} + \pi_{t+h}^{c,-2})} & \text{si } \pi_{t+h}^{c,1} \geq \pi_{t+h}^{c,2} \\ \frac{\pi_{t+h}^{c,2} - \pi_{t+h}^{c,1}}{(\pi_{t+h}^{c,+2} + \pi_{t+h}^{c,-1})} & \text{si } \pi_{t+h}^{c,2} \geq \pi_{t+h}^{c,1} \end{cases} \quad (4-9)$$

Il est à noter que cette formule diffère de celle présentée dans [136], que nous avons mise en avant lors d'une conférence CIRED. Dans cet article, nous avons considéré les remboursements dus à des erreurs de prévision du DLR dans le terme pénalisant  $\Delta_{SW}^{-'}$ , ce qui n'est pas le cas dans l'approche proposée ici (4-10) :

$$\Delta_{SW}^{-'} = \begin{cases} 0 & \text{si } NTC_{t+h}^* \geq NTC_{t+h}^c \\ (\pi_{t+h}^{c,+1} + \pi_{t+h}^{c,-2} + |\pi_{t+h}^{c,1} - \pi_{t+h}^{c,2}|) \cdot (NTC_{t+h}^c - NTC_{t+h}^*) & \text{si } NTC_{t+h}^* < NTC_{t+h}^c \text{ et } \pi_{t+h}^{c,+1} \geq 1 \\ (\pi_{t+h}^{c,+2} + \pi_{t+h}^{c,-1} + |\pi_{t+h}^{c,1} - \pi_{t+h}^{c,2}|) \cdot (NTC_{t+h}^c - NTC_{t+h}^*) & \text{si } NTC_{t+h}^* < NTC_{t+h}^c \text{ et } \pi_{t+h}^{c,+1} < 1 \end{cases} \quad (4-10)$$

## 4.4. Remarques sur les coûts pour le gestionnaire de réseau

Dans l'approche décrite dans la section 4.3.2, on fait une hypothèse importante, celle d'un monopole verticalement intégré, situation dans laquelle les producteurs électriques et les gestionnaires de réseau sont réunis dans une même entité. Or, dans un contexte de dérégulation des marchés de l'électricité, cette hypothèse tend à être fautive. Il faut alors noter l'existence de plusieurs termes de pertes pour le gestionnaire de réseau non pris en compte dans l'équation à minimiser. En effet, l'augmentation de la NTC est une initiative du gestionnaire de réseau qui se traduit par un transfert économique de sa part vers les producteurs électriques, ce qui peut pousser le gestionnaire de réseau à adopter une stratégie différente de celle que nous proposons dans ce chapitre.

### 4.4.1.1. Variation de la rente de congestion.

Lorsque des producteurs d'électricité vendent une part de leur production sur un autre marché en utilisant des lignes congestionnées, ces acteurs payent au gestionnaire de réseau une rente de congestion avec un mécanisme d'offre et de demande pour pouvoir utiliser la capacité d'échange.

Le prix pour l'utilisation de la NTC étant fixé selon des mécanismes de marché, on peut estimer que le prix pour l'utilisation de la NTC est égal à la différence de prix entre les deux marchés  $|\pi_{t+h}^{c,2} - \pi_{t+h}^{c,1}|$ .

Le fait de modifier la NTC d'un état  $NTC_{SLR}$  vers un état  $NTC_{t+h}^c = NTC^{SLR} + \delta_{NTC}^+$  modifie la rente de congestion de  $\Delta_{rente}$  (€), l'hypothèse posée par les équations (4-4)-(4-5) selon laquelle les prix de l'électricité dans les deux marchés ne varient pas avec l'évolution de la TTC n'étant pas considérée ici :

$$\Delta_{rente} = NTC_{t+h}^c \cdot |\pi_{t+h}^{c,2,\delta_{NTC}^+} - \pi_{t+h}^{c,1,\delta_{NTC}^+}| - NTC^{SLR} \cdot |\pi_{t+h}^{c,2} - \pi_{t+h}^{c,1}| \quad (4-11)$$

On peut décomposer cette équation de la manière suivante, où  $\Delta_{rente}^+$  est un bénéfice pour le GRT et  $\Delta_{rente}^-$  une perte financière :

$$\Delta_{rente} = \Delta_{rente}^+ - \Delta_{rente}^- \quad (4-12)$$

$$\Delta_{rente}^+ = (NTC_{t+h}^c - NTC^{SLR}) \cdot (\pi_{t+h}^{c,2,\delta_{NTC}^+} - \pi_{t+h}^{c,1,\delta_{NTC}^+}) \quad (4-13)$$

$$\Delta_{rente}^- = NTC^{SLR} \cdot [(\pi_{t+h}^{c,2} - \pi_{t+h}^{c,1}) - (\pi_{t+h}^{c,2,\delta_{NTC}^+} - \pi_{t+h}^{c,1,\delta_{NTC}^+})] \quad (4-14)$$

Avec notre hypothèse de non-variation des coûts (4-4)-(4-5), le terme  $\Delta_{rente}^-$  est nul et on estime alors que la croissance de la NTC permet au gestionnaire de réseau d'augmenter ses revenus.

Or, si les différences de prix initiales sont importantes, l'augmentation de la NTC aura probablement pour effet de modifier les prix spots et de fortement estomper les différences entre les prix sur les deux

marchés. Le terme de perte  $\Delta_{\text{rente}}^-$  pourrait alors être important devant le terme de gain  $\Delta_{\text{rente}}^+$ , entraînant une perte de revenus significative pour le gestionnaire de réseau, au profit des autres acteurs du réseau électrique.

#### 4.4.1.2. Coût des erreurs de prévision du DLR

Si le gestionnaire de réseau doit abaisser la NTC par rapport à celle mise en vente sur le marché spot,  $NTC_{t+h}^* < NTC_{t+h}^c$ , et si l'on considère les coûts d'équilibrage inchangés, on peut poser que ces derniers se diviseront en deux parties. Tout d'abord un coût associé aux activations de réserve dont nous avons parlé ci-dessus (4-15) :

$$\Delta_{SW}^{-,1} = (\pi_{t+h}^{c,+1} + \pi_{t+h}^{c,-2}) \cdot (NTC_{t+h}^c - NTC_{t+h}^*) \quad \text{si } NTC_{t+h}^* < NTC_{t+h}^c \quad (4-15)$$

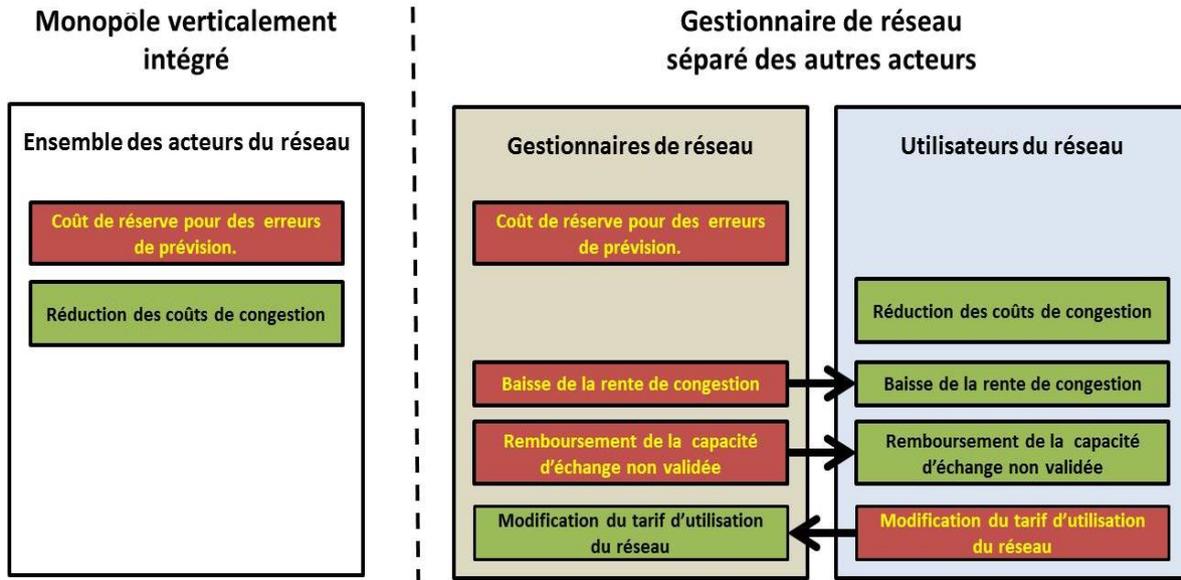
Ensuite, un deuxième terme de coût associé aux dépenses du GRT pour rembourser la part de rente de congestion achetée et supprimée (4-16). L'existence de ce terme n'est pas évidente, mais il pourrait cependant être considéré :

$$\Delta_{SW}^{-,2} = |\pi_{t+h}^{c,1} - \pi_{t+h}^{c,2}| \cdot (NTC_{t+h}^c - NTC_{t+h}^*) \quad \text{si } NTC_{t+h}^* < NTC_{t+h}^c \quad (4-16)$$

#### 4.4.1.3. Conclusion : besoin d'une modification du tarif d'utilisation du réseau ou de stratégies alternatives.

On a vu initialement qu'une approche poussant le gestionnaire de réseau à maximiser ses revenus était fautive. Cela l'aurait en effet poussé à congestionner ses lignes pour limiter la NTC mise en vente, ce qui ne correspond pas à la réalité. On se base alors sur des stratégies de maximisation du bien-être social pour définir une nouvelle fonction objectif. Cette approche est souvent mise en avant dans la littérature, mais elle se base sur une hypothèse de monopole verticalement intégré, et ne tient pas compte des transferts financiers de la part du gestionnaire de réseau vers les utilisateurs du réseau électrique.

Dans ce chapitre, nous travaillons à partir d'une hypothèse de monopole verticalement intégré. Dans un travail futur, on pourrait supposer la mise en place d'une nouvelle méthode de tarification des gestionnaires de réseau, ou comme nous le verrons dans le chapitre suivant, la mise en place de méthodologies alternatives pour limiter les pertes occasionnées auprès des GRT tout en permettant une amélioration significative des bénéfices permis par les prévisions DLR. Les gains et pertes évoqués dans cette section sont résumés sur la **Figure 4-3**.



**Figure 4-3.** Résumé des gains (en vert) et des pertes financières (en rouge) associées à l'utilisation de prévisions DLR, pour un monopole verticalement intégré ou considérant une séparation entre les différents acteurs du réseau.

## 4.5. Cas d'étude

### 4.5.1. Prévisions DLR

On considère comme cas d'étude une ligne virtuelle localisée à la frontière entre la France et la Belgique. Similairement au cas d'étude des chapitres 2 et 3, on considèrera que la ligne est constituée d'un câble Lynx 175 mm<sup>2</sup>, orienté sur l'axe est-ouest. Les données météorologiques considérées sont collectées sur une seule station météorologique opérée par météo France, localisée à la position (50,58°N, 3,09°E), et on estime que les valeurs d'ampacité calculée pour cette station sont valables pour toute la ligne considérée.

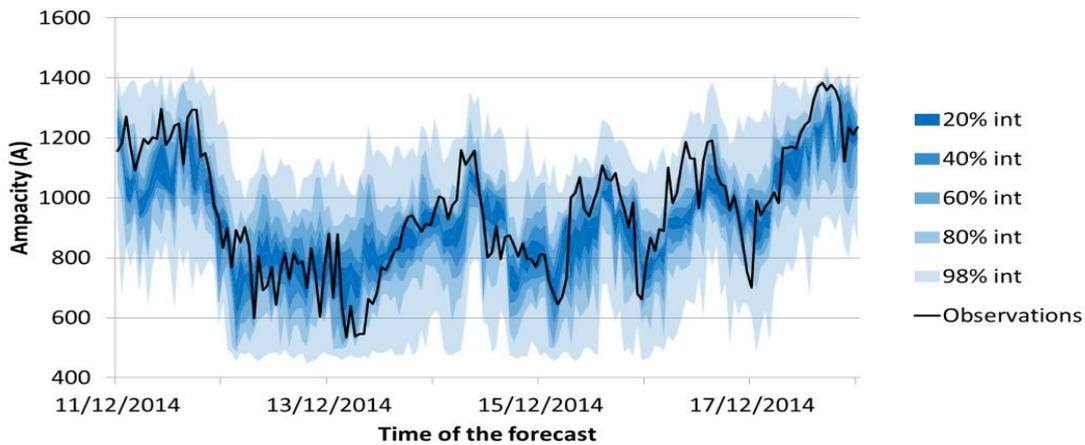
Pour les prévisions, on utilise un modèle de régression quantile par forêt aléatoire comme dans les chapitres 2 et 3, entraîné avec des prévisions ECMWF fournies pour les coordonnées [(50,5°N, 3,0°E), (50,5°N, 3,125°E), (50,625°N, 3,0°E), (50,625°N, 3,125°E)].

On entraîne le modèle à l'aide de 16 variables explicatives, correspondant aux prévisions météorologiques pour les 4 positions, pour les paramètres suivants :

- La vitesse méridionale du vent à 10m (m/s)
- La vitesse zonale du vent à 10m (m/s)
- La température ambiante (°C)
- L'irradiation solaire globale (W/m<sup>2</sup>)

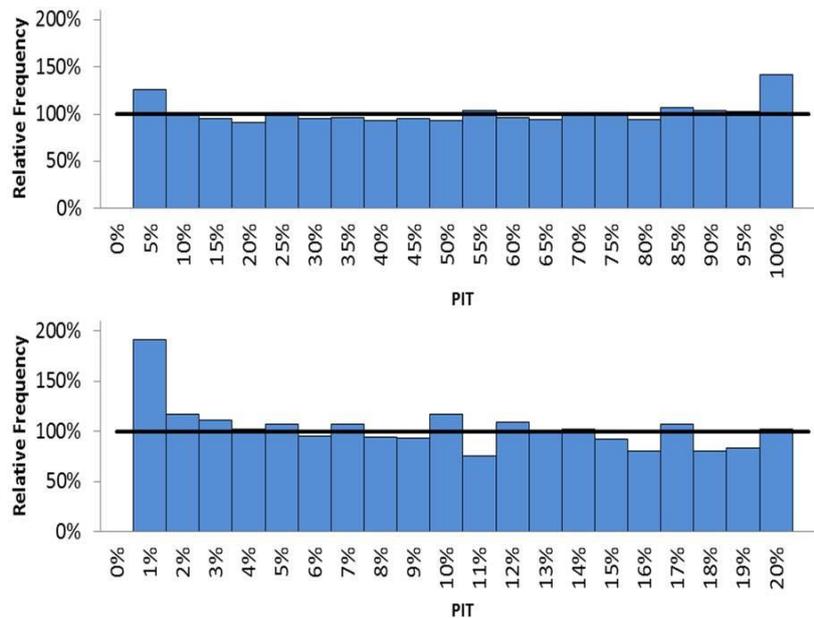
Le modèle fournit des prévisions tous les jours faites à 12h00, pour des horizons allant de 24 heures à 47 heures.

Comme dans le chapitre 3, le modèle est entraîné à partir de fenêtres glissantes de 6 mois, réactualisées tous les mois. Les données utilisées sont des données horaires collectées pour les années 2014 et 2015. Un échantillon des prévisions obtenues est montré sur la **Figure 4-4**.



**Figure 4-4.** Observations DLR et prévisions probabilistes pour le cas considéré, avec des prévisions faites tous les jours à 12h00 et des horizons de prévisions allant de 24 à 47 heures.

Pour des horizons à 24 heures, le modèle est caractérisé par un MAPE de 16,7%, à comparer à un MAPE de 20,8% pour un modèle persistance. La fiabilité est illustrée sur la **Figure 4-5**. Au regard des résultats relatifs à la fiabilité dans le chapitre 2, nous jugeons ces résultats comme satisfaisants pour des prévisions DLR.



**Figure 4-5.** Diagrammes PIT pour des niveaux de probabilité de 0%-100% et 0%-20%.

#### 4.5.2. Coûts Spot et coûts d'équilibrage

On considère comme données pour les prix spots et les prix d'équilibrage des données historiques observées sur les marchés belges et français. Pour cela, on utilise des données de prix spots collectées

auprès d'EPEX et de BELPEX pour la période de l'année 2014, et des données de prix d'équilibrage collectées auprès des gestionnaires de réseau de transport français RTE et belge Elia.

La méthodologie que nous avons proposée repose sur la connaissance à l'avance des futurs prix spot et prix d'équilibrage. Or, des prévisions de ces prix sont difficiles à obtenir, et pour avoir une approche plus réaliste, dans [77], il est proposé de considérer que ces prix peuvent avoir des valeurs moyennes et non ponctuelles parfaitement prévues pour des périodes données. Ces prix moyens sont utilisés par la suite, et on reprendra ici cette approche, en utilisant des coûts moyens de l'électricité sur l'année 2014 (**Tableau 4-1**).

**Tableau 4-1.** Evolution des prix de l'électricité moyens (€/MWh) sur les marchés français (1) et belge (2). Les valeurs sont calculées à partir des données de l'année 2014, seules les données de prix pour midi étant considérées.

	Valeurs mensuelles						Valeurs trimestrielles						Valeurs annuelles						
	$\pi^{c,1}$	$\pi^{c,2}$	$\pi^{+,1}$	$\pi^{-,1}$	$\pi^{+,2}$	$\pi^{-,2}$	$\pi^{c,1}$	$\pi^{c,2}$	$\pi^{+,1}$	$\pi^{-,1}$	$\pi^{+,2}$	$\pi^{-,2}$	$\pi^{c,1}$	$\pi^{c,2}$	$\pi^{+,1}$	$\pi^{-,1}$	$\pi^{+,2}$	$\pi^{-,2}$	
Janvier	46,4	49,2	48,0	46,0	54,4	53,1													
Février	54,4	57,5	58,7	51,3	58,4	56,9	48,5	53,4	53,3	47,4	54,2	52,8							
Mars	45,4	53,8	53,7	45,1	50,3	48,9													
Avril	41,2	53,0	49,2	52,4	38,9	37,2													
Mai	29,6	45,3	37,0	42,3	39,3	38,5	35,9	48,4	44,9	43,6	45,2	44,1							
Juin	37,0	46,9	48,7	36,1	57,5	56,8							42,3	52,2	44,5	44,1	54,4	53,4	
Juillet	43,2	49,7	52,0	37,3	52,3	50,4													
Août	36,2	49,3	39,9	43,9	66,2	65,1	40,3	52,9	43,2	42,2	59,5	58,2							
Septembre	41,4	59,9	37,6	45,5	59,9	59,2													
Octobre	49,2	72,4	43,0	52,7	94,3	93,5													
Novembre	45,7	48,5	34,7	43,5	44,1	43,4	44,6	54,0	37,0	43,3	58,8	58,2							
Décembre	38,8	41,0	33,1	33,7	37,5	37,0													

## 4.6. Résultats

On considère dans un premier temps l'utilisation de percentiles fixés, allant de 1% à 99%. On mesure la performance des quantiles utilisés en évaluant les modèles avec la valeur moyenne du bien-être social sur les N points de l'échantillon de test, ici les données de l'année 2015 (4-17).

$$\overline{SW} = \frac{1}{N} \sum_{k=1}^N SW_k \quad (4-17)$$

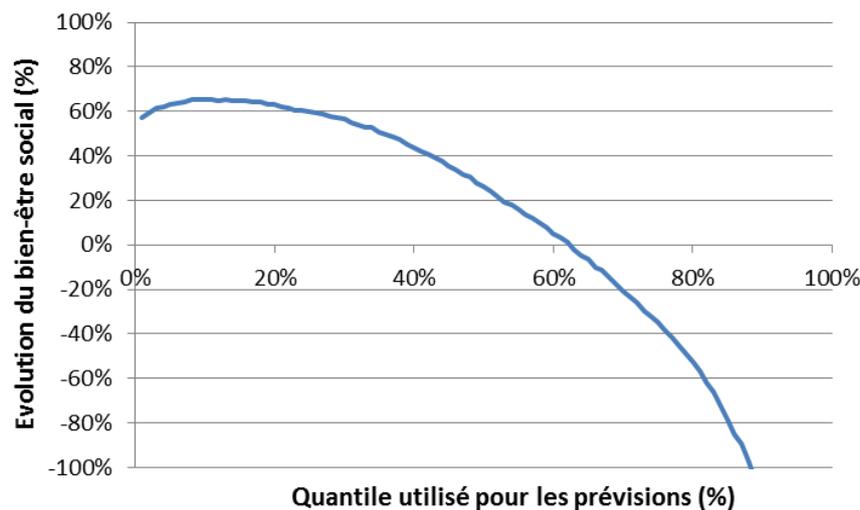
Par la suite, on normalise par rapport à la valeur de  $SW_{perf}$ , obtenue lorsque des prévisions DLR parfaites sont utilisées.

$$SW_{nor} = \frac{\overline{SW}}{SW_{perf}} \quad (4-18)$$

Les valeurs des dépenses associées aux activations de réserve seront aussi normalisées de la même manière par rapport à la valeur  $SW_{perf}$ . Le résultat est montré sur la **Figure 4-6**.

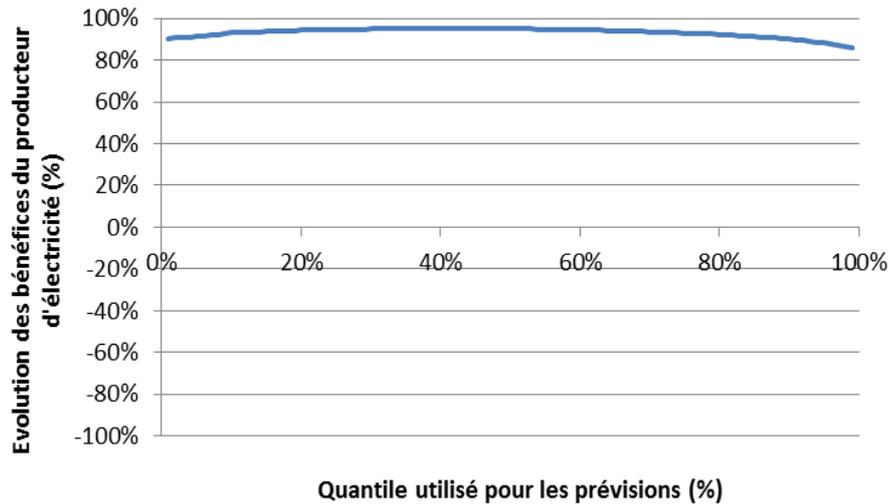
On peut avec ce résultat d'abord illustrer les pénalités financières associées à l'utilisation de prévisions médianes, les bénéfices associés à l'utilisation de ces prévisions étant près de 3 fois inférieurs aux bénéfices associés à l'utilisation du SLR. La prise en compte des risques pour le gestionnaire de réseau est souvent l'argument mis en avant pour justifier l'utilisation de quantiles bas pour la prévision DLR, mais on constate ici que même en se limitant à une analyse économique omettant ces critères de risque, des prévisions à bas quantile sont nécessaires, les bénéfices les plus importants étant associés aux quantiles inférieurs à 20%.

Le quantile optimal, correspondant au maximum des bénéfices observés sur la **Figure 4-6**, est égal à 9%, donc supérieur aux quantiles bas habituellement utilisés pour des prévisions DLR. Il est aussi intéressant de signaler que des variations de sélection de quantile autour de cette valeur entraînent des modifications de la variation de SW qui sont relativement faibles. Pour un quantile variant entre 5% et 20%, l'évolution de l'indice  $SW_{nor}$  reste supérieure à 60%.



**Figure 4-6.** Evolution du SW en fonction de quantiles fixés entre 1% et 99%. La valeur de bénéfices de 100% correspond à l'utilisation de prévisions parfaites.

Il est ici intéressant de faire remarquer la différence entre les courbes obtenues pour le DLR, et une courbe obtenue pour le même type de méthodologie adaptée à une prévision de production EnR. On représente une telle courbe sur la **Figure 4-7**, en utilisant la même échelle que dans la **Figure 4-6**. Le résultat est basé sur un ensemble de prévisions pour une station PV localisée dans le sud-ouest de la France, les prix spot et d'équilibrage pour l'année 2016 étant utilisés pour calculer les pertes et les gains du producteur.



**Figure 4-7.** Evolution des revenus d'un producteur d'énergie photovoltaïque en fonction de quantiles arbitrairement sélectionnés entre 1% et 99%. La valeur de bénéfices de 100% correspond à l'utilisation de prévisions parfaites.

Comme on le voit, pour un producteur EnR, l'évolution des bénéfices est beaucoup moins marquée avec le choix du quantile que pour l'utilisateur de prévisions DLR. La différence entre les formes des deux courbes est due à la différence des mécanismes de rétroaction. Un producteur qui aurait sous-estimé sa production sur le marché day-ahead sera en mesure de vendre son surplus de production lors de l'étape du marché d'ajustement, et donc de toucher un revenu malgré son erreur de prévision. A l'inverse, un gestionnaire de réseau devra acheter cette production, et sera très pénalisé en cas de surestimation de prévision. Par la suite et pour l'utilisations des prévisions DLR, on considère l'utilisation de quantiles moyens optimisés pour des périodes annuelles, trimestrielles et mensuelles. Comme on le voit sur le tableau **Tableau 4-2**, l'utilisation de quantiles dynamiques saisonniers, variant sur des périodes trimestrielles ou mensuelles permet des améliorations par rapport à l'utilisation d'un quantile annuel optimal. On notera aussi que le fait de définir un quantile optimal à partir des valeurs moyennes annuelles permet d'obtenir des performances proches du meilleur quantile fixe possible. L'amélioration apportée par l'utilisation de quantiles égaux à des valeurs mensuelles est relativement faible, de l'ordre de 13,9% là où un quantile fixe arbitraire donnait une amélioration de 12,8%.

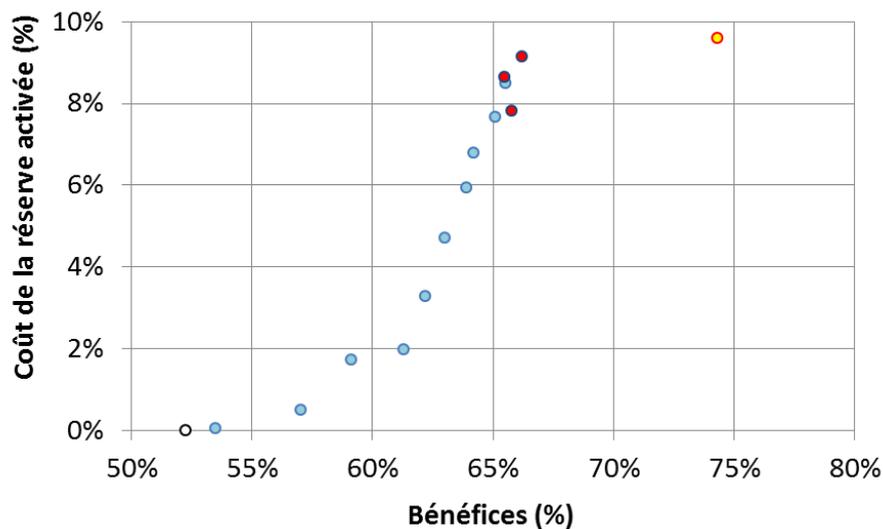
Il est en revanche à noter que l'utilisation de quantiles basés sur une prévision parfaite des prix spots et des prix d'équilibrage permet une amélioration significative des bénéfices, avec une augmentation de  $SW_{nor}$  de 22%.

Aussi, on constate que l'utilisation de quantiles très bas, ici 0.1%, permet de conserver un degré de bénéfices non négligeable, un rapport de 1 à 10 étant observé par rapport à la solution de quantile à 9%, mais le tout avec des coûts de réserve divisés par un facteur supérieur à 100, passant de 0.85% à 0.01%. On remarque aussi, résultat sur lequel nous reviendrons dans le chapitre suivant, que le rapport entre les bénéfices et les dépenses du gestionnaire de réseau n'est pas faible, de l'ordre de 1 à 2 pour la situation la plus critique.

**Tableau 4-2.** Gain en termes de  $SW_{nor}$  et d'augmentation du DLR.

	Bénéfices en termes de bien-être social (%)	Coût de la réserve activée (%)	Electricité échangée (%)
TTC nulle	0,0	0,0	0,0
SLR	52,3	0,0	51,1
Quantile 0,1%	53,5	0,1	52,1
Quantile 1%	57,0	0,5	56,8
Quantile 3%	61,3	4,7	63,8
Quantile 5%	63,0	7,8	68,3
Quantile 9%	65,5	8,5	74,1
Quantile Année -2015	65,1	8,5	71,8
Quantile Trimestre -2015	65,8	7,8	73,3
Quantile Mois -2015	66,2	9,1	74,3
Prévision de prix parfaite	74,3	9,6	70,2
Prévision DLR parfaite	100	0,0	100

Pour aller plus loin sur ce point, il est intéressant de représenter sur un graphique l'évolution du coût de la réserve en fonction des bénéfices apportés par l'utilisation du DLR. Sur la **Figure 4-8**, on représente l'ensemble des résultats obtenus pour les différentes stratégies considérées.



**Figure 4-8.** Evolution des coûts associés aux activations de réserve dues aux erreurs de prévisions DLR, en fonction des bénéfices en termes de bien-être social obtenus par l'utilisation de la ligne. En bleu, sont représentés les stratégies à quantile fixes ; en rouge les points associés à des stratégies de quantiles saisonniers ; en blanc le point associé à l'utilisation du SLR et en jaune le point associé à des prévisions dynamiques avec une connaissance parfaite des prix à l'avance.

On remarque que le coût de l'amélioration des bénéfices a une forme exponentielle : une augmentation des bénéfices de 5% se traduit par une multiplication des coûts de réserve par un facteur proche de 4.

On peut alors poser que le gestionnaire de réseau, ayant les frais d'activation de réserve à sa charge, pourrait être intéressé à limiter l'augmentation des bénéfices associés au DLR de manière à limiter fortement ses charges financières, associées aux surestimations des prévisions DLR.

## 4.7. Conclusions

On a pu voir ici que la méthodologie proposée pouvait présenter des bénéfices conséquents par rapport à une méthodologie utilisant des prévisions à quantile fixe. Là où une amélioration relative de 9% des bénéfices de la ligne est observée lors de l'utilisation de prévisions DLR à quantile 1% par rapport à l'utilisation du SLR, on progresse vers une amélioration relative de 42% lorsque sont utilisées des prévisions utilisant des quantiles dynamiques fixés avec des coûts connus à l'avance.

Il y a plusieurs critiques à faire par rapport à une telle méthodologie. Tout d'abord, on a proposé ici une méthodologie cherchant à maximiser le bien-être social, mise en place par un acteur qui est le gestionnaire de réseau. Une telle stratégie aurait du sens dans un contexte de monopole verticalement intégré : un seul acteur posséderait à la fois les activités de transport d'électricité et de production d'électricité. Or la plupart du temps, il y a une séparation à faire entre deux ensembles d'acteurs :

- Les utilisateurs du réseau, les producteurs et les consommateurs, qui profitent de l'augmentation de la capacité de transfert des lignes sur le réseau avec l'augmentation du bien-être social.
- Le gestionnaire de réseau, prenant à sa charge les pénalités possibles dues aux erreurs de prévision du DLR et aux variations de la rente de congestion.

Même si le gestionnaire de réseau pourrait envisager de nouvelles méthodes de tarification pour pallier ses pertes, il est probable que celui-ci cherchera dans un premier temps à les conserver relativement basses. Surtout, on a vu que les charges du GRT associées aux surestimations des prévisions DLR tendaient à croître de manière exponentielle avec les bénéfices associés au DLR, ce qui renforce l'hypothèse que les GRT chercheront probablement à avoir des bénéfices légèrement plus faibles, mais limitant très fortement leurs charges.

Ces points doivent être pris en considération dans la mise en place de la stratégie, qui devra donc être averse aux risques de pertes, alors qu'ici elle est neutre par rapport à ces charges.

A cela, on ajoutera que de nombreuses hypothèses de simplification ont été faites ici, en ignorant les caractéristiques du réseau. Certaines de ces simplifications sont importantes :

- L'évolution des prix par rapport à l'évolution de la NTC dépend de caractères arbitraires. Un modèle plus complexe pourrait prendre en compte l'évolution des prix de marché avec la NTC, et par exemple la convergence des prix en cas de valeur de prévision DLR suffisamment élevée.
- La NTC augmente avec le DLR avec un ratio de 1 pour 1. Or, comme on l'a évoqué pour un cas d'étude de réseau, ce rapport n'a rien d'évident, surtout pour les réseaux maillés qui sont opérés à des niveaux de tension HTB.
- On a aussi considéré que la capacité d'échange de la ligne croissait infiniment avec le DLR, ce qui est aussi faux pour des réseaux maillés.

Dans le chapitre suivant, pour limiter l'influence de ces points, nous ferons une étude similaire à celle faite ici mais avec un modèle plus complexe, qui tient compte des caractéristiques spécifiques d'un cas d'étude de réseau électrique IEEE. De plus, en plus de prendre en compte l'amélioration du bien-être social, d'autres paramètres auxquels le GRT serait sensible comme les coûts des activations de réserve à sa charge seront aussi considérés.

# CHAPITRE 5

## Impact des prévisions du Dynamic Line Rating sur la gestion d'un réseau électrique

---

### 5.1. Introduction

Dans le chapitre 4, nous avons montré l'existence d'un intérêt significatif au développement de méthodologies d'utilisation des prévisions DLR. Cependant, plusieurs difficultés étaient mises en avant avec l'approche présentée, et nous souhaitons dans ce chapitre aller vers des modèles plus développés permettant de dépasser ces points.

Ainsi, avec l'approche du chapitre 4, il était tout d'abord impossible de considérer les caractéristiques de l'évolution de la capacité d'échange avec l'ampacité des lignes, les changements de l'ampacité de certaines lignes pouvant entraîner des évolutions limitées de la capacité d'échange. Pour illustrer cela, nous avons pris l'exemple d'un réseau IEEE pour lequel la variation de l'ampacité d'une ligne congestionnée au-delà de 125% de sa valeur initiale ne permettait plus d'augmenter la capacité d'échange entre deux zones, d'autres lignes devenant congestionnées. Ici, on se propose corriger ce premier point en travaillant avec des simulations de réseau électrique pour pouvoir prendre en compte la structure du réseau dans l'utilisation du DLR.

Nous avons aussi considéré une absence d'impact du DLR sur l'évolution des prix dans le chapitre précédent. Or une amélioration des capacités d'interconnexions doit permettre une convergence des prix. Ici, on considère pour modéliser l'évolution des coûts de l'électricité avec le DLR les coûts unitaires de production des générateurs sur un réseau et leurs niveaux de production, dans le cadre du développement d'approche d'optimisation stochastique.

Ensuite, l'analyse ne prenait pas en compte l'aversion potentielle du gestionnaire de réseau à assumer des pertes financières importantes pour permettre l'augmentation du bien-être social. En effet, pour un point où on atteint un maximum du bien-être social, localement, l'augmentation du bien-être social d'un euro se traduit par la perte d'un euro pour le gestionnaire de réseau qui assume les pertes, et nous estimons cette situation comme non satisfaisante pour le GRT. Dans le cas du chapitre 4, nous avons observé que des bénéfices à un niveau donné entraînaient des coûts pour le gestionnaire de réseau égaux

à la moitié des gains, ce qui pose la question complexe d'une modification du tarif d'utilisation du réseau qui viserait à compenser ces pertes. On propose dans ce chapitre une approche visant à maximiser le bien-être social, tout en maintenant les pertes du gestionnaire de réseau sous un seuil donné.

Enfin, nous n'avons pas considéré dans l'étude précédente l'aversion du gestionnaire de réseau à des situations où des erreurs de prévisions importantes étaient faites. Par exemple, dans l'approche proposée au chapitre 4 et à observations de prix similaire, deux situations avec des surestimations du DLR futurs de 25 A auraient eu le même impact qu'une situation où une surestimation de 50 A eu été observée. Les risques d'accident impliqués dans la deuxième situation étant beaucoup plus importants que dans la première, cette approche serait difficile à considérer comme représentative du comportement du gestionnaire de réseau. De même que l'approche évoquée au précédent point visant à maximiser le bien-être social en maintenant des pertes financières pour le GRT limitées, nous proposons une autre approche visant à maximiser le bien-être social tout en gardant une fréquence faible de situations où les erreurs de prévisions DLR ont un coût supérieur à un seuil donné.

En plus de la résolution de ces problématiques évoquées en conclusion du chapitre 4, un autre apport de ce chapitre est l'utilisation de prévisions DLR réalistes. Dans la plupart des travaux relatifs au développement d'approches d'optimisation stochastique prenant en compte des prévisions DLR, comme [60], [61], [96], les auteurs utilisent une seule prévision DLR virtuelle, aux caractéristiques arbitrairement fixée. Ici, on se propose d'utiliser des ensembles de prévisions DLR fournies pour une année avec des modèles de prévision différents. En se référant aux modèles présentés dans le chapitre 2 et 3, nous proposons alors d'évaluer la valeur ajoutée de certaines améliorations apportées aux modèles de prévision.

## 5.2. Méthodologie

Dans le chapitre 4, nous avons travaillé avec un problème où la capacité d'échange transfrontalière, la TTC, était considérée. Utilisée pour des simulations de réseau, une approche visant à définir la TTC avec le DLR ne permet pas de prendre en compte des caractéristiques économiques, le problème résolu étant un Optimal Power Flow où les coûts d'utilisation des générateurs sont fixés à 0€/MWh ou -1€/MWh fonction de l'appartenance des générateurs aux deux zones connectées. En prenant en compte des simulations de réseau, une approche de définition de la TTC avec une optimisation économique semble alors difficile à définir, et une autre approche est à privilégier.

On évoquera ici une approche qui a été imaginée dans le cadre de cette thèse et qui permettrait de définir la TTC en accord avec des prévisions du DLR, même si cette approche n'a pas été développée et serait une perspective intéressante à étudier à la suite de notre travail.

L'idée de cette approche repose sur le fait que l'ampacité statique occasionne des risques, en raison du fait que le SLR est généralement défini tel que 1% du temps, il soit inférieur à la valeur dynamique de l'ampacité de la ligne. Considérant une fonction évaluant le coût d'un éventuel dépassement, ainsi que les probabilités associées à ces dépassements sur une année, il est possible de définir un coût associé au risque de l'utilisation du SLR. Une telle en fonction de coût n'est pas présentée dans la littérature, même si il est évoqué que celle-ci aurait une forme exponentielle ou quadratique dans [61]–[63]. En utilisant des prévisions probabilistes du DLR dans une approche stochastique, il serait théoriquement possible de définir en J-1 une valeur de prévision du DLR qui serait associée à un risque équivalent au risque moyen associé à l'utilisation du SLR. Une telle approche a le mérite de ne pas reposer sur des prévisions de

différentes variables, contrairement à l'approche du chapitre précédent qui repose sur la prévision des futurs coûts de réserve, et pourrait être mise en pratique par des gestionnaires de réseau ayant à gérer des capacités d'échange transfrontalières congestionnées pour des raisons de limites thermiques.

Dans ce chapitre, nous avons décidé de travailler avec une autre approche, basée sur celle décrite dans [60]. Dans cet article, les auteurs travaillent sur un problème d'Optimal Power Flow, où les coûts du système sont minimisés en tenant compte d'une composante stochastique associée à des prévisions DLR. Nous travaillons ici avec le même problème, mais en considérant des prévisions DLR réalistes pour une année entière, ainsi que des modifications sur la fonction objectif de manière à ajouter l'aversion du GRT à des pertes financières à sa charge ou à un nombre important d'erreurs ayant un coût important, ce type d'erreur pouvant être considérées comme des événements occasionnant des risques importants.

La forme de ce problème et ses différents termes sont décrits dans la suite de cette section.

### 5.2.1. Forme générale du problème : problème d'optimisation stochastique

Le problème est défini comme associé à la réalisation de deux étapes différentes dans le temps, de manière similaire au chapitre 4 :

- En J-1, on prend une décision de dispatch des productions électriques, en tenant compte de la réduction des coûts et d'une prévision de la future valeur du DLR.
- A l'instant t où se réalise les opérations prévues en J-1, on engage des actions de correction fonction des hypothétiques erreurs de prévisions, comme par exemple des activations de réserve.

Des étapes intermédiaires constituées par les opérations faites sur le marché infra-journalier ne sont pas considérées. Comme cela est dit dans [60], ce problème a une forme d'optimisation stochastique à deux étapes (*two-stage stochastic optimization*).

### 5.2.2. Description de la fonction objectif

L'ensemble des études relatives [60], [61], [96] à l'implémentation du DLR dans la gestion de réseau électrique se basent sur la minimisation de fonctions coûts qui sont de la forme suivante :

$$L = C_g + C_{\text{allocation}} + C_{\text{reserve}} + C_{\text{load}} + C_{\text{DLR}} \quad (5-1)$$

où  $C_g$  est le coût du dispatch ;  $C_{\text{allocation}}$  est le coût d'allocation des réserves ;  $C_{\text{reserve}}$  et  $C_{\text{load}}$  sont les coûts associés aux actions de correction au niveau des générateurs et des charges ;  $C_{\text{DLR}}$  est un coût virtuel, associé aux risques dus à des situations où le courant d'une ligne est supérieur au DLR. Ces différents termes sont décrits ci-dessous.

#### 5.2.2.1. Coût de dispatch, $C_g$

Le terme  $C_g$  représente les coûts associés aux productions électriques prévues dans le dispatch. Ce terme est généralement décrit de la manière suivante :

$$C_g = \sum_{g=1..N_g} (\text{pfuel}_{g,2} \cdot P_g^2 + \text{pfuel}_g \cdot P_g + I_g \cdot \text{fix}_g) \quad (5-2)$$

$$\text{s. t.} \quad \underline{P}_g \leq P_g \leq \bar{P}_g \quad \forall g \in N_g \quad (5-3)$$

$$I_g \in \{0,1\} \quad (5-4)$$

où  $I_g$  est une variable binaire traduisant la mise en fonction ou non du générateur ;  $P_g$  (MW) est la puissance fournie par un générateur  $g$ , limitée par des valeurs minimales  $\underline{P}_g$  et maximales  $\overline{P}_g$  ;  $\pi_{fix_g}$  (€) est le coût fixe associé à l'utilisation d'un générateur  $g$  ;  $\pi_{fuel_{g,2}}$  (€/MWh) et  $\pi_{fuel_g}$  (€/MWh<sup>2</sup>) sont des prix associés à l'utilisation du fuel.

Les études relatives au DLR font certaines simplifications par rapport à cette équation. Par exemple :

- [60] ne considère pas la partie quadratique des coûts de génération, afin de fournir une fonction objective linéaire en accord avec la formulation du problème sous forme d'optimisation linéaire en nombres entiers.
- [96] pose que tous les termes  $I_g$  sont égaux à 1.

### 5.2.2.2. Coûts d'allocation, $C_{allocation}$

Le terme  $C_{allocation}$  représente les coûts de l'allocation de réserve. Ceux-ci peuvent être fixés comme associés au pire scénario possible, par exemple la surestimation maximale du DLR futur lorsque seul ce paramètre présente des incertitudes sur sa valeur future.

Il est à noter que la surestimation maximale, dans le cas du DLR, correspond souvent à la différence entre la valeur prévue du DLR et une valeur seuil, généralement le SLR, par rapport à laquelle le DLR ne peut être inférieur.

$$C_{allocation} = \sum_{g=1..N_g} (\pi h_g^{up} \cdot H_g^{up} + \pi h_g^{do} \cdot H_g^{do}) \quad (5-5)$$

$$\text{s. t.} \quad 0 \leq H_g^{up} \leq \overline{H}_g^{up} \cdot I_g \quad \forall g \in N_g \quad (5-6)$$

$$0 \leq H_g^{do} \leq \overline{H}_g^{do} \cdot I_g \quad \forall g \in N_g \quad (5-7)$$

$$H_g^{up} \leq \overline{P}_g - \underline{P}_g \quad \forall g \in N_g \quad (5-8)$$

$$H_g^{do} \leq \overline{P}_g - \underline{P}_g \quad \forall g \in N_g \quad (5-9)$$

où  $H_g^{up}$  (MW) et  $H_g^{do}$  (MW) sont les réserves à la hausse et à la baisse allouées pour chaque générateur ;  $\pi h_g^{up}$  (€/MW) et  $\pi h_g^{do}$  (€/MW) sont les prix de ces allocations.

### 5.2.2.3. Coûts des actions de correction, $C_{reserve}$ et $C_{load}$

Le terme  $C_{reserve}$  est associé aux coûts d'activation de réserve en cas d'erreurs de prévision, que ce soit le DLR ou d'autres variables comme des productions d'EnR futures. Il est défini de diverses manières dans les articles évoqués. Dans la majorité des cas, on évalue ces coûts dans la fonction objectif comme étant liés aux informations relatives aux valeurs futures de DLR possibles et aux niveaux de probabilité associés.

On citera [96] où une exception est faite, les coûts de réserve attendus n'étant pas considérés, mais seulement les coûts d'activation de réserve dans le cas le plus pessimiste.

Différentes approches posent le comment les activations de réserve sont allouées entre les différents producteurs d'électricité. Dans [60], il est proposé d'allouer ces ressources de manière à minimiser les coûts d'activation de ces réserves. A l'inverse, dans un autre type de méthodologie présenté dans [96], une mise en place de politiques affines est proposée. Cette approche permet un réglage des niveaux de génération pour les différents générateurs d'une certaine manière similaire à ce qui est fait pour le réglage primaire de la fréquence sur les réseaux électriques : les corrections faites pour chaque

générateur sont proportionnelles à la magnitude de la surestimation du DLR, le même rapport de variation étant utilisé dans tous les cas.

Ici, on utilisera un approche similaire à celle proposée dans [60], et la fonction  $C_{\text{reserve}}$  sera décrite comme suit :

$$C_{\text{reserve}} = \sum_{s \in N_s} \sum_{g=1..N_g} \rho_s (\pi_r^{\text{up}} \cdot R_{g,s}^{\text{up}} + \pi_r^{\text{do}} \cdot R_{g,s}^{\text{do}}) \quad (5-10)$$

$$\text{s. t.} \quad 0 \leq R_{g,s}^{\text{up}} \leq H_g^{\text{up}} \quad \forall g \in N_g, \forall s \in N_s \quad (5-11)$$

$$0 \leq R_{g,s}^{\text{do}} \leq H_g^{\text{do}} \quad \forall g \in N_g, \forall s \in N_s \quad (5-12)$$

où  $R_{g,s}^{\text{up}}$  (MW) et  $R_{g,s}^{\text{do}}$  (MW) sont les réserves activées par les générateurs  $g$  dans le cas de la réalisation d'un scénario  $s$ ;  $\pi_r^{\text{up}}$  (€/MWh) et  $\pi_r^{\text{do}}$  (€/MWh) sont les prix des activations de réserve;  $N_s$  représente un ensemble de réalisations possibles  $s$  à considérer ayant chacune une probabilité  $\rho_s$  de se réaliser.

En complément aux études prenant en compte des corrections faites au niveau des générateurs, peu d'études proposent de considérer des opérations de dispatch tenant compte d'effacements de charges volontaires ou non, comme par exemple [65]. Nous n'avons pas considéré ce deuxième type d'actions dans ce travail, et nous avons alors fixé le terme  $C_{\text{load}}$  comme nul.

#### 5.2.2.4. Coûts de dépassement de l'ampacité des lignes équipées de DLR, $C_{\text{DLR}}$

Le dernier terme  $C_{\text{DLR}}$  représente des pénalités associées à des courants qui seraient supérieurs au DLR dans les lignes équipées de DLR.

En général il est posé comme nul, ce qui se traduit par le fait que les activations de réserves sont telles que les courants sont inférieurs ou égaux au DLR observé à l'instant  $t+h$ , soit dans les conditions normales d'utilisation, soit dans lors de la réalisation de n'importe quel incident sur un des ouvrages du réseau.

Il est cependant possible de considérer que des dépassements légers du courant par rapport au DLR peuvent être acceptés, et n'entraînent pas alors la mise en place d'actions de correction. Pour ce faire, on définit des coûts virtuels associés à ces dépassements lorsqu'ils se produisent.

Cela est proposé dans [61]–[63], et la contrainte associée au respect de l'ampacité des lignes est alors transformée en coût ajouté dans la fonction objectif. Considérant le terme  $\delta_{s,l} \geq 0$  (MW) représentant la différence entre le courant passant dans une ligne  $l$  et une valeur de DLR associée qui serait inférieure dans le cadre de la réalisation d'un scénario  $s$ , les coûts supplémentaires dans la fonction objectif sont modélisés de différentes manières dans les différents articles évoqués :

- Soit de manière linéaire par morceaux :

$$C_{\text{DLR}} = \sum_{s \in N_s} \sum_{l \in L} [\pi_l^{\text{OL}} \cdot a_{s,l} + \pi_l^{\text{OD}} \cdot b_{s,l}] \quad (5-13)$$

Où  $\pi_l^{\text{OL}}$  (€.MW<sup>-1</sup>) est un coût associé à des dépassements légers inférieurs à une valeur seuil  $OL_l^{\text{max}}$  (MW), et  $\pi_l^{\text{OD}}$  (€.MW<sup>-1</sup>) à des dépassements importants supérieurs à  $OL_l^{\text{max}}$ , les valeurs des termes  $a_{s,l}$  (MW) et  $b_{s,l}$  (MW) étant définis ainsi :

$$a_{s,l} + b_{s,l} = \delta_{s,l} \quad (5-14)$$

$$0 \leq a_{s,l} \leq OL_l^{\text{max}} \quad (5-15)$$

$$0 \leq b_{s,l} \quad (5-16)$$

- Soit de manière quadratique, avec un terme  $\pi_l^{\text{quad}}$  ( $\text{€} \cdot \text{MW}^{-2}$ ) étant défini par le gestionnaire de réseau :

$$C_{\text{DLR}} = \sum_{s \in N_s} \sum_{l \in L} [\pi_l^{\text{quad}} \cdot (\delta_{s,l})^2] \quad (5-17)$$

- Pour ce deuxième point, il est à signaler que les auteurs estimaient qu'une fonction exponentielle était préférable pour modéliser l'évolution de  $C_{\text{DLR}}$ , des termes  $\pi_l^{\text{exp}}$  (U.A.) et  $a_{l,\text{exp}}$  ( $\text{MW}^{-1}$ ) étant arbitrairement définis. Cependant, pour simplifier les calculs des matrices hessienne et jacobienne, des fonctions quadratiques étaient généralement privilégiées.

$$C_{\text{DLR}} = \sum_{s \in N_s} \sum_{l \in L} [\pi_l^{\text{exp}} \cdot \exp(a_{l,\text{exp}} \cdot \delta_{s,l})] \quad (5-18)$$

Dans ces études, le choix pour modéliser  $C_{\text{DLR}}$  est arbitraire, et la réflexion autour de la forme de cette fonction, modélisant la gravité des risques potentiels associés aux dépassements du DLR, est actuellement un sujet non abordé dans la littérature. De plus, ces études ne prennent pas en compte des incidents potentiels sur les éléments du réseau. Or, si ceux-ci sont pris en compte et peuvent occasionner des dépassements de courant par rapport aux ampacités des lignes qui se traduisent par des coûts, il est alors nécessaire de considérer les probabilités d'incidents sur les éléments des lignes, et une approche corrective N-1 apparaît comme indispensable avec de tels coûts (i.e. si un incident se produit sur un élément d'une ligne, des modifications peuvent être nécessaires pour respecter les contraintes du réseau).

Dans notre travail, nous avons privilégié une approche préventive pour la gestion des contraintes N-1, l'ensemble des incidents possibles sur les éléments sur le réseau ne pouvant entraîner le dépassement d'une contrainte du réseau même lorsque aucune action de recours n'est possible, et nous fixons la valeur de  $C_{\text{DLR}}$  comme nulle.

## 5.3. Problème d'optimisation stochastique

### 5.3.1. Problème – Hypothèse de monopole verticalement intégré

Ici, on pose que  $C_{\text{DLR}} = 0$ , et on imposera donc des rétro-actions abaissant les courants dans les lignes de manière à être inférieurs à leurs ampacités pour l'ensemble des scénarios d'incident considérés.

Une remarque pourrait être soulevée sur le pourquoi, dans notre travail, des actions de correction sont nécessaires pour des erreurs de prévisions DLR, et non pas des incidents N-1. Cela est dû à deux raisons. La première est une raison de simplicité car il n'est pas nécessaire de prendre en compte les risques d'incident du réseau, et la deuxième est le fait que là où un incident sur un ouvrage du réseau peut nécessiter un temps de réaction très court, des erreurs de prévision du DLR peuvent être résolues dans un intervalle de plusieurs dizaines de minutes, en raison de l'inertie de la température du câble d'une ligne électrique. Il peut alors être plus facile de mettre en place des actions de recours pour des prévisions DLR erronées que pour certains incidents d'ouvrages du réseau.

On peut, à partir des formules présentées dans la section 5.2.2 et de l'équation (5-1), définir une première fonction objectif :

$$\min \left\{ \begin{array}{l} \sum_{g=1..Ng} (\pi_{fuel_g} \cdot P_g + \pi_{fix_g} \cdot I_g) + \\ \sum_{g=1..Ng} (\pi_{hup_g} \cdot H_g^{up} + \pi_{hdo_g} \cdot H_g^{do}) + \\ \sum_{s \in N_s} \sum_{g=1..Ng} \rho_s (\pi_{rup_g} \cdot R_{g,s}^{up} + \pi_{rdo_g} \cdot R_{g,s}^{do}) \end{array} \right\} \quad (5-19)$$

Différentes contraintes sont à ajouter :

$$\underline{P}_g \leq P_g \leq \bar{P}_g \quad \forall g \in N_g \quad (5-20)$$

$$I_g \in \{0,1\} \quad \forall g \in N_g \quad (5-21)$$

$$0 \leq H_g^{up} \leq \bar{H}_g^{up} \cdot I_g \quad \forall g \in N_g \quad (5-22)$$

$$0 \leq H_g^{do} \leq \bar{H}_g^{do} \cdot I_g \quad \forall g \in N_g \quad (5-23)$$

$$H_g^{up} \leq \bar{P}_g - P_g \quad \forall g \in N_g \quad (5-24)$$

$$H_g^{do} \leq P_g - \underline{P}_g \quad \forall g \in N_g \quad (5-25)$$

$$0 \leq R_{g,s}^{up} \leq H_g^{up} \quad \forall g \in N_g, \forall s \in N_s \quad (5-26)$$

$$0 \leq R_{g,s}^{do} \leq H_g^{do} \quad \forall g \in N_g, \forall s \in N_s \quad (5-27)$$

$$\sum_{g \in G_n} (P_g + R_{g,s}^{up} - R_{g,s}^{do}) + \sum_{l_n \in L_n} f_{s,l_n} = D_n \quad \forall g \in N_g, \forall s \in N_s \quad (5-28)$$

$$f_{s,l} = P_{nom} \cdot \frac{\theta_{s,n_1(l)} - \theta_{s,n_2(l)}}{X_l} \quad \forall s \in N_s, \forall l \in A \cup B \quad (5-29)$$

$$\theta_{s,n_{ref}} = 0 \quad \forall s \in N_s \quad (5-30)$$

$$f_{s,l} \leq \bar{F}_{l,max} \quad \forall l \in A, \forall s_1 \in N_{s_1}, \forall s_2 \in N_{s_2} \quad (5-31)$$

$$f_{s,l} \leq \Delta_{s,l} \cdot \bar{F}_{l,max} \quad \forall l \in B, \forall s \in N_s \quad (5-32)$$

$$\underline{\Delta}_l \leq \Delta_{s,l} \leq \bar{\Delta}_l \quad \forall s_2 \in N_s \quad (5-33)$$

Les contraintes (5-20)-(5-27) sont celles évoquées dans la partie 5.2.2, relatives aux coûts d'allocation et d'activation de réserve.

La contrainte (5-28) traduit le fait qu'en chaque nœud n, les puissances doivent s'équilibrer. Le terme  $D_n$  (MW) représente la puissance consommée au nœud n,  $f_{s,l_n}$  (MW) représente la puissance arrivant au nœud n au travers de la ligne  $l_n$ ,  $G_n$  représente l'ensemble des générateurs connectés au nœud n et  $L_n$  représente l'ensemble des lignes connectées au nœud n.

La contrainte (5-29) est la loi d'Ohm généralisée, et lie le courant passant dans une ligne à la différence de tension entre ses deux bornes. Les hypothèses DC permettent [137] de simplifier cette équation :

- La résistance est négligée devant l'inductance.
- La tension est en magnitude égale en magnitude à 1p.u. sur tout le réseau.
- La différence entre les phases de tension entre deux nœuds voisins est faible.

Ici les paramètres sont les phases  $\theta_{s,n_1(l)}$  et  $\theta_{s,n_2(l)}$  (rad) des tensions aux nœuds  $n_1$  et  $n_2$ , le courant passant dans la ligne  $f_{s,l}$  (MW), l'inductance de la ligne  $X_l$  (p.u.) et  $P_{nom}$  (MW) est la puissance nominale correspondant à 1p.u.

On pose avec la contrainte (5-30) que la phase de la tension est nulle en un nœud  $n_{ref}$  de référence.

Toutes les études prenant en compte la prévision du DLR pour des opérations de dispatch prennent en compte ces hypothèses DC. En revanche, on signalera que les études sur la coordination

électrothermique [138], qui prennent en compte le DLR pour des opérations transitoires faites dans des délais inférieurs à une heure, prennent généralement en compte un problème de modélisation de flux de puissance AC.

L'hypothèse DC peut apparaître comme problématique dans le cas de l'étude du DLR, en raison du fait qu'elle empêche de prendre en compte les problématiques de chutes de tension. Or, comme on l'avait évoqué dans le chapitre 1, les chutes de tension peuvent devenir limitantes pour les courants passant dans des lignes présentant des évolutions d'ampacité significatives. Ici, on pose l'hypothèse que si pour un état initial où le SLR est utilisé, il n'y a que des limitations dues à des congestions, cela reste le cas lorsque le DLR est utilisé.

Cette hypothèse peut être validée car pour les cas d'étude utilisés dans le travail de cette thèse, les variations du DLR sont régulièrement limitées pour trois raisons :

- Soit à cause des limitations induites par d'autres lignes dans des réseaux maillés, qui déplacent les congestions des lignes équipées avec le DLR vers d'autres lignes, à partir de certains seuils.
- Soit à cause des phénomènes de congestion levés pour des variations du DLR restant peu significatives,
- Soit à cause des contraintes imposées par le gestionnaire de réseau pour limiter les risques.

Pour donner un ordre de grandeur pour les deux premiers points, aucune de nos simulations n'a permis de trouver des bénéfices à une augmentation du DLR au-delà de 130% de la valeur du SLR. On peut alors poser que les variations de DLR ne font pas évoluer la nature de la limite de courant d'un problème de limitation de température à un problème de limitation de chute de tension, et on conserve alors dans notre approche l'hypothèse DC.

Les contraintes (5-31) et (5-32) sont les contraintes associées aux limites de courant  $\bar{F}_{l,max}$  (MW), si la ligne  $l$  appartient à l'ensemble des lignes A non équipées avec le DLR, ou  $\Delta_{s,l} \bar{F}_{l,max}$ , si la ligne  $l$  appartient à l'ensemble des lignes B équipées avec le DLR. Le terme  $\Delta_{s,l}$  correspond au ratio entre la valeur du DLR pour une ligne  $l$  observée avec un scénario  $s$  et la valeur du SLR dans la même ligne.

Enfin, (5-33) est une contrainte supplémentaire sur  $\Delta_{s,l}$  pour poser que le DLR utilisé ne peut être inférieur à une valeur minimale  $\underline{\Delta}_l \bar{F}_{l,max}$ , par exemple  $\underline{\Delta}_l = 1$  pour le SLR, ni supérieur à une valeur  $\bar{\Delta}_l \bar{F}_{l,max}$ , ces deux valeurs étant fixées par le gestionnaire de réseau. Ces contraintes peuvent être ignorées, mais il est raisonnable de poser que le GRT ne prendrait pas en compte des valeurs de DLR inférieures au SLR, et donc des phénomènes de congestion plus contraignant que lorsque le SLR est utilisé, de même qu'il pourrait souhaiter limiter les variations maximales permises par le DLR.

Comme dans [60], on a alors ici un problème d'optimisation linéaire en nombre entier.

### 5.3.2. Problème– Ajout de l'aversion au risque

On ne considère ici plus qu'un ensemble  $N_{s,DLR}$  de scénarios associés à des observations de DLR, et non l'ensemble des observations associées aux différents processus stochastiques.

On cherche maintenant à ajouter une aversion au risque de la part du gestionnaire de réseau dans l'équation à minimiser. Nous nous sommes ici inspiré de [124], où les auteurs proposaient une

méthodologie de prise de décision où la fonction objectif prenait compte de l'indice de l'Expected Energy Not Supplied (EENS) :

$$C_{C_g, EENS}(s) = C_g(s) + k_{EENS} \cdot v_{EENS}(s) \quad (5-34)$$

où  $k_{EENS}$  est un terme constant défini en accord avec les objectifs du GRT, et  $v_{EENS}$  une fonction définie arbitrairement par les gestionnaires de réseau.

Pour traduire l'aversion au risque du GRT, les auteurs proposent de définir la fonction  $v_{EENS}$  comme une fonction exponentielle :

$$v_{EENS}(s) = \frac{e^{\beta \cdot z(s)} - 1}{e^{\beta} - 1} \quad (5-35)$$

$$z(s) = \frac{EENS^{\max} - EENS^s}{EENS^{\max} - EENS^{\min}} \quad (5-36)$$

Les valeurs  $EENS^{\max}$  et  $EENS^{\min}$  étant des valeurs d'EENS utilisées pour normaliser l'EENS,  $EENS^s$  est la valeur de l'EENS pour un scénario  $s$ , et  $\beta$  est un paramètre permettant soit de traduire l'aversion au risque du GRT pour des erreurs importantes (lorsque  $\beta > 0$ ), soit de traduire sa volonté de réduire l'EENS nonobstant les risques d'erreurs importantes (lorsque  $\beta < 0$ ).

Ici, on se propose une approche similaire, mais au lieu de considérer le comportement du GRT par rapport à l'EENS, on considère son comportement par rapport aux conséquences des erreurs de prévision du DLR dans notre modèle d'optimisation, ici les coûts de réserve  $C_{\text{reserve}}$ .

Il est à faire remarquer que l'ajout d'une telle modification à la fonction objectif peut impacter le dispatch des générations  $P_g$  et le unit commitment des générateurs  $I_g$  fonction des risques d'erreur sur le DLR. Ainsi, un générateur pourrait ne pas être activé en raison de la forme de l'aversion du gestionnaire de réseau à des risques d'erreur de prévision du DLR, ce qui n'est pas réaliste dans une première approche. Un tel résultat est à éviter, et il est alors nécessaire de découpler le problème en un problème multi-objectif, de manière à ce que le setting des générateurs ne soit pas influencé par l'aversion au risque du GRT. On cherche alors à optimiser le problème d'optimisation biniveau suivant :

$$\min_{x \in X, y \in Y} (f_{\text{GRT}}(x, y)) \quad (5-37)$$

s. t.

$$G_i(x, y) \leq 0 \text{ for } i \in \{1, 2, \dots, I\} \quad (5-38)$$

$$y \in \arg \min_{z \in Y} \{f_{\text{prod/cons}}(x, z) : g_j(x, z) \leq 0, j \in \{1, 2, \dots, J\}\} \quad (5-39)$$

où :

où :

$$f_{\text{prod/cons}}(x, y) = \left\{ \sum_{g=1..Ng} (\pi_{\text{fuel}_g} \cdot P_g + \pi_{\text{fix}_g} \cdot I_g) \right\} \quad (5-40)$$

$$f_{\text{GRT}}(x, y) = \left\{ \begin{array}{l} \sum_{g=1..Ng} (\pi_{\text{fuel}_g} \cdot P_g + \pi_{\text{fix}_g} \cdot I_g) + \\ \sum_{g=1..Ng} (\pi_{\text{hur}_g} \cdot H_g^{\text{up}} + \pi_{\text{hdo}_g} \cdot H_g^{\text{do}}) + \\ \left( \sum_{s \in N_s} \sum_{g=1..Ng} \rho_s (\pi_{\text{rup}_g} \cdot R_{g,s}^{\text{up}} + \pi_{\text{rdo}_g} \cdot R_{g,s}^{\text{do}}) \right) \end{array} \right\} \quad (5-41)$$

Les contraintes  $G_i$  sont les mêmes contraintes que les contraintes (5-20)-(5-33), et les contraintes  $g_j$  sont les mêmes moins l'ensemble des contraintes associées aux allocations de réserve et aux activations de réserve.

Les variables décisionnelles du niveau supérieur (*upper level decision vector*,  $x$ ) sont les valeurs du DLR prévu, les valeurs d'allocation de réserve et les valeurs d'activations de réserve. Les variables décisionnelles du niveau inférieur sont les niveaux de génération prévus ( $P_g$ ) et la liste des générateurs activés ( $I_g$ ) (*lower-level decision vector*,  $y$ ). Seules les valeurs de DLR prévues, décidées avec le problème leader (5-37)-(5-38), influence la résolution du problème follower (5-39).

L'ajout d'incertitudes sur des éléments autres comme la génération intermittente ou une incertitude sur la charge modifierait ces fonctions. Une question qui se poserait serait alors de savoir qui a la responsabilité de l'activation de la réserve dans cette équation : si une activation de réserve à la hausse pour un générateur est nécessaire en cas de deux erreurs de prévisions, une à la responsabilité du GRT et une à la responsabilité des producteurs/consommateurs, il faudrait pouvoir poser qui aurait à charge les pénalités de ces erreurs au cas où les deux se produiraient en même temps. Cette question n'est pas abordée dans ce travail, où nous ne considérons que l'incertitude sur la prévision du DLR, mais elle serait à prendre en compte dans un travail futur.

Afin d'ajouter l'aversion au risque de la part du gestionnaire de réseau sur les coûts de réserve  $C_{\text{Reserve}}$ , on modifie la fonction  $f_{\text{GRT}}$  en ajoutant une en fonction de pénalité  $v_\beta$  dépendant d'un paramètre  $\beta$  :

$$f_{\text{GRT},v}(X) = \left\{ \begin{array}{l} \sum_{g=1..Ng} (\pi_{\text{fuel}_g} \cdot P_g + \pi_{\text{fix}_g} \cdot I_g) + \\ \sum_{g=1..Ng} (\pi_{\text{hup}_g} \cdot H_g^{\text{up}} + \pi_{\text{hdo}_g} \cdot H_g^{\text{do}}) + \\ v_\beta \left( \sum_{s \in N_s} \sum_{g=1..Ng} \rho_{s_2} (\pi_{\text{rup}_g} \cdot R_{g,s}^{\text{up}} + \pi_{\text{rdo}_g} \cdot R_{g,s}^{\text{do}}) \right) \end{array} \right\} \quad (5-42)$$

Pour définir la fonction  $v_\beta$ , on peut reprendre les fonctions évoquées pour le calcul des coûts associés aux dépassements du DLR par le courant passant dans les lignes [61]–[63]. Dans ces articles, les auteurs considéraient 3 méthodologies que nous reprenons ici :

- Une approche linéaire. Ici, une approche simple étant privilégiée, nous n'avons pas considéré d'approche linéaire par morceaux comme dans [61]–[63], mais une approche continue :

$$v_\beta(x) = x + \beta \cdot x, \beta \geq 0 \quad (5-43)$$

- Une modélisation quadratique :

$$v_\beta(x) = x + \beta \cdot x^2, \quad \beta \geq 0 \quad (5-44)$$

- Une modélisation exponentielle similaire à la fonction proposée dans [124] :

$$v_\beta(x) = \frac{e^{\beta \cdot x} - 1}{e^\beta - 1}, \beta \geq 0 \quad (5-45)$$

Les deux premières formes d'équation présentent les avantages de conserver une certaine simplicité pour la résolution du problème posé, en permettant au problème de conserver une forme quadratique ou

linéaire. La forme linéaire a l'inconvénient de ne pas permettre de mettre en avant l'aversion du GRT à des erreurs de magnitudes importantes, ce que permet la forme quadratique. La troisième forme exponentielle, même si elle ne permet plus une résolution aussi aisée, peut être considérée comme plus proche de l'aversion au risque du gestionnaire du réseau.

## 5.4. Méthode de résolution

Le problème évoqué, sans la fonction  $v_\beta$ , correspond à un problème d'optimisation linéaire en nombres entiers résoluble par solveur. Des solveurs comme Gurobi fournissent en effet des fonctions permettant directement de résoudre ce type de problèmes [139]. Dans un premier travail auquel nous avons participé, l'outil FICO Xpress [140] a par exemple été utilisé pour résoudre les problèmes d'optimisation linéaire en nombre entiers associé à l'utilisation de prévisions DLR et éoliennes.

Une telle approche est chronophage, la résolution du problème pour un pas de temps pouvant prendre quelques secondes. Or, nous souhaitons pouvoir faire les tests pour un nombre de prévisions DLR important correspondant à des prévisions faites pour plusieurs mois, considérant un nombre de valeurs de paramètre  $\beta$  aussi important, plusieurs types de fonction  $v_\beta$  ainsi que différents modèles de prévision.

A ces points, on ajoutera que notre problème est aussi plus complexe que celui présenté dans la littérature, en raison d'un nombre de contraintes plus élevé. En effet, nous avons ajouté des contraintes N-1, et des calculs décrits en 5.4.2.2 étaient alors nécessaires pour générer les contraintes associées par décomposition de Benders [141]. On signalera ici que ces contraintes étaient nécessaires non seulement pour avoir une approche du problème plus réaliste, mais aussi car sans elles, il était difficile de pouvoir obtenir un cas d'étude de réseau maillé où des niveaux de charge raisonnables étaient observés en même temps que des phénomènes de congestion.

En raison du nombre de simulations requis et du nombre de contraintes, il n'était pas possible de faire nos études en utilisant une méthodologie de résolution traditionnelle, et nous avons donc fait plusieurs hypothèses et simplifications pour pouvoir travailler à partir de tables de correspondance et ainsi pouvoir générer des résultats dans un temps raisonnable.

### 5.4.1. Hypothèses et simplifications

#### 5.4.1.1. Incertitudes considérées et actions de recours

Ici, on travaille sur un cas où seules des incertitudes sur le DLR sont considérées comme pouvant entraîner des rétroactions. Il est considéré que le réseau est géré de manière préventive pour pouvoir respecter le critère N-1 sans qu'il y ait nécessité d'activer des réserves en cas d'incident.

Seuls les incidents sur les lignes ont été considérés dans notre cas lors de la programmation des simulations car pour certains cas de calculs de TTC, seuls ces incidents sont considérés dans les contraintes N-1 [53]. Il est à noter que la plupart des études faites sur la prise en compte du DLR dans le dispatch ne prennent pas en compte les critères N-1.

#### 5.4.1.2. Générateurs activés

Dans le problème considéré, on définit les activations des générateurs comme associés à des variables binaires  $I_g$ . On pose que les augmentations des prévisions du DLR ne permettent pas dans notre approche

de modifier la répartition des générateurs activés. Le fait que les générateurs voyant leurs puissances dispatchées modifiées doivent par la suite participer à l'allocation de réserve au cas où il y ait erreur de prévision du DLR renforce cette hypothèse, un générateur désactivé grâce à l'augmentation d'une prévision DLR ne pouvant plus participer à l'allocation de réserve. Dans le cas où des dépassements de l'ampacité de la ligne seraient autorisés, cette affirmation serait en revanche à discuter.

On définit alors les variables  $I_g$  seulement avec un problème d'optimisation réalisé avec l'ensemble des valeurs d'ampacité fixées égales aux valeurs de SLR.

#### 5.4.1.3. Puissance générée pour un scénario $s$

Pour un scénario  $s$ , la puissance générée par un générateur  $P_{g,s}$  dépend de la puissance dispatchée et de la réserve activée.

$$P_{g,s} = P_g + R_{g,s}^{\text{up}} - R_{g,s}^{\text{do}} \quad (5-46)$$

On considère que la puissance  $P_{g,s}$  en cas d'erreur de prévision est indépendante des décisions prises sur le dispatch et des prévisions DLR, à l'exception du paramètre  $I_g$ . Il est alors possible d'obtenir  $P_{g,s}$  à partir de la résolution d'un DCOPF, en fixant  $I_g$  préalablement et en ayant seulement les valeurs de DLR. Cette hypothèse est réaliste pour notre cas d'étude en particulier, car comme dans [60], on considère que tous les générateurs peuvent participer aux activations de réserve, et que les coûts pour ces activations sont proportionnels au coût de dispatch avec le même ratio pour tous les générateurs.

On résumera ici l'idée importante derrière cette hypothèse, qui dépend essentiellement du cas d'étude choisi dans notre travail et dans [60] : le cas d'étude utilisé est relativement simple car tous les générateurs activés peuvent participer à l'activation de réserve, et les coûts d'activations de réserve sont proportionnels aux coûts de dispatch. Ici, plutôt que de prendre un cas d'étude plus complexe, on exploite ces caractéristiques simples pour pouvoir poser des hypothèses qui permettent par la suite de définir les tables de correspondance que nous avons évoquées dans l'introduction de cette section.

### 5.4.2. Description des outils

#### 5.4.2.1. Solveurs utilisés

Le problème d'optimisation présenté ici a été implémenté avec l'outil PyPower [142], un portage de MatPower sur Python [143]. Deux fonctions ont été utilisées, les fonctions *rundcpf* et *rundcopf*, qui permettent respectivement de faire un *DC Power Flow* (DCPF) et un *DC Optimal Power Flow* (DCOPF).

L'OPF fourni par MatPower présente deux limitations : il ne permet pas de prendre en compte des contraintes de sécurité N-1, et il ne permet pas de faire de *unit de-commitment*, c'est-à-dire de décider que certains générateurs peuvent être désactivés pour réduire les coûts. Certains outils comme l'outil *Matpower Optimal Scheduling Tool (MOST)*[144] permettent de dépasser ces limites, mais nous proposons ici de continuer d'utiliser l'outil PyPower avec des programmes développés pour prendre en compte les critères N-1 et la composante en nombres entiers. Le choix de cet outil a été fait pour deux raisons :

- La première raison était une raison pratique : notre première piste de recherche était sur l'observation de l'impact du DLR sur la TTC dans un réseau, et dans ce contexte l'outil PyPower était tout à fait adapté et avait été utilisé. De premiers travaux ayant été fait avec cet outil, il était plus simple de continuer le travail avec PyPower que de faire un portage vers un autre outil.
- Le fait de créer les outils associés aux contraintes N-1 et le *unit commitment* permettait de s'assurer de la prise en compte de certains critères souhaités, comme par exemple le fait d'imposer dans le *unit commitment* le respect des contraintes N-1 en le combinant avec des décompositions de Benders ou encore la possibilité de modifier le programme générant les contraintes N-1 pour, par exemple, permettre d'ignorer certaines zones de réseau opérées de manière radiale.

#### 5.4.2.2. Implantation des contraintes N-1 avec une décomposition de Benders

Pour une configuration de réseau donné, les résultats d'un OPF peuvent ne pas permettre de respecter les contraintes du réseau en cas d'incident sur un élément du réseau.

Le problème à résoudre est alors à modifier, en ajoutant un ensemble de contraintes associées aux incidents potentiels. Le problème pouvant devenir volumineux, nous avons ici utilisé des décompositions de Benders [141] pour simplifier les calculs. Le principe est basé sur l'idée de « diviser pour régner », un problème d'optimisation ayant un nombre de contraintes important étant divisé en un problème maître et un ensemble de sous-problèmes. L'algorithme utilisé est décrit ci-dessous :

- On effectue les étapes suivantes tant que des contraintes sont générées à chaque fin de cycle  $n$  :
  1. Un DCOPF est fait, et les puissances sortantes des générateurs  $P_{g,n}$  sont retenues. Le DCOPF est fait avec un ensemble de contraintes additionnelles vide pour le premier cycle.
  2. Pour chacune des lignes du réseau, les opérations suivantes sont faites :
    - a. Avec les puissances sortantes des générateurs enregistrées  $P_{g,n}$ , des DCPF sont faits, en posant que la ligne considérée est hors service.
    - b. Si sur une ligne restante  $l$ , le courant est supérieur à l'ampacité d'une valeur  $\Delta_{l,n}^+$ , alors les étapes suivantes sont faites :
      - i. Pour chaque générateur activé, un DCPF est fait, tel que :
        1. La puissance de sortie est modifiée de manière à être égale à  $P_{g,n} + 1\text{MW}$ .
        2. La variation de courant dans la ligne  $l$ , est enregistrée, égale à  $\delta_{l,g}$ .
      - ii. Une contrainte est générée :

$$\Delta_{l,n}^+ + \sum_{g=1..N_g} \delta_{l,g}(P_g - P_{g,n}) \leq 0 \quad (5-47)$$

3. Si des contraintes sont générées lors de l'étape 2, elles sont ajoutées au set de contraintes et on recommence un cycle à l'étape 1. Si aucune contrainte n'est générée, l'algorithme est terminé.

Les contraintes obtenues à la fin sont ajoutées à la description du réseau, et peuvent alors être considérées lors de l'utilisation de la fonction *rundcopf* pour le calcul des DCOPF. L'ajout de ce programme au DCOPF permet alors d'obtenir un *N-1 security-constrained DC optimal power flow* (SCOPF).

#### 5.4.2.3. Unit commitment

Il est possible de faire un OPF avec *unit commitment* sous PyPower en utilisant la fonction *runuopf*. Cette approche ne vise pas à résoudre un problème d'optimisation en nombres entiers, mais utilise une

approche heuristique pour sélectionner les générateurs activés. Cependant nous avons eu des difficultés à utiliser cet outil avec les matrices de contraintes ajoutées en raison de la génération des coupes de Benders. Nous nous sommes alors inspirés de l'heuristique proposée par les développeurs de la fonction *runuopf* alors pour écrire un nouveau code, tenant compte des contraintes de Benders.

Ici, on a considéré que l'ensemble des situations où des problèmes n'étaient pas résolubles étaient dus à des situations où trop de générateurs étaient activés, la situation inverse n'étant pas considérée comme possible pour le réseau étudié, celui-ci ayant été dimensionné pour des valeurs de consommation élevées. Pour l'ensemble des situations considérées, le traitement suivant a permis d'obtenir des configurations de générateurs activés pour lesquels les problèmes de DCOPF étaient résolubles.

Pour un réseau à  $N_g$  générateurs, notre algorithme suit les étapes suivantes :

1. A l'étape  $N = 0$ , l'ensemble des générateurs du réseau sont considérés comme allumés.
2. Si la somme des limites inférieures des puissances fournies par les générateurs est supérieure à la demande, le problème n'étant pas résoluble, un générateur est désactivé. Ce générateur est choisi comme celui dont le coût du MW activé est le plus cher ( $\pi_{fix_g}/P_g$ ). Cette étape est répétée jusqu'à ce que la condition décrite soit respectée. Chaque générateur désactivé est retenu dans une liste.
3. Des coupes de Benders sont générées avec le problème considéré, les générateurs retenus à l'étape 2 étant désactivés.
4. Un DCOPF est fait, le problème étant modifié pour prendre en compte des générateurs désactivés de l'étape 2 et les contraintes de Benders de l'étape 3. Si le problème n'est pas résoluble, on suit les étapes suivantes jusqu'à ce que le problème soit résoluble. A la fin du processus l'ensemble des contraintes de Benders générées sont supprimées<sup>1</sup>:
  - a. Parmi les générateurs activés, on désactive le générateur aux coûts de MW activé le plus cher.
  - b. On génère à nouveau des coupes de Benders.
  - c. Si avec les nouvelles contraintes et les générateurs désactivés, dont celui ajouté à l'étape 4.a, le problème de DCOPF est résoluble, on efface les contraintes générées par décomposition de Benders, et on passe à l'étape suivante en maintenant les générateurs trouvés à l'étape 4.a désactivés.
5. Les étapes suivantes sont faites tant qu'il n'est plus possible de réduire les coûts de fonctionnement :
  - a. Un DCOPF est résolu, la liste des générateurs retenus étant désactivés. Les coûts globaux du système sont considérés comme la meilleure solution.
  - b. Pour chacun des générateurs activés :
    - i. un DCOPF est fait en le considérant comme désactivé. Si les coûts globaux sont réduits par rapport à l'étape a, alors :
      1. Des coupes de Benders sont générées avec le problème considéré.

<sup>1</sup> Il eut été possible de séparer les contraintes générées par les décompositions de Benders, entre celles générées pour des congestions sur des lignes équipées de DLR et celles sans. La deuxième catégorie de contraintes eut alors été inchangée pour l'ensemble des DCOPF faits dans la suite pour une situation de charge donnée, et les coupes générées sur des lignes équipées de DLR eurent pu être modifiées en accord avec la valeur de DLR. En effaçant les contraintes à des étapes régulières, le temps de calcul était alors augmenté car des mêmes contraintes devaient être générées à plusieurs étapes. Ces considérations n'ont pas été prises en compte, les temps de calcul étant jugés raisonnables.

2. On fait un nouveau DCOPF avec le même générateur désactivé, avec les nouvelles contraintes, et on vérifie si les coûts globaux de fonctionnement du système sont réduits.
- c. Pour les générateurs qui ont été désactivés, si certains ont permis des réductions des coûts globaux, alors celui ayant permis la réduction des coûts la plus importante est ajouté à la liste des générateurs désactivés.
6. A la fin du processus, les coupes de Benders sont effacées, et les générateurs désactivés voient leurs puissances minimales et maximales fixées à 0MW.

#### 5.4.2.4. Processus de génération des tables de correspondance (Lookup Table)

Avec les hypothèses et les outils décrits ci-dessus, on a alors choisi d'obtenir la valeur de la prévision  $\Delta$  du DLR à l'aide d'une table de correspondance, celle-ci étant générée à partir de plusieurs SCOPF. On fera remarquer que cette solution a été inspirée d'une approche, développée par le groupe Economie, Fonctionnement et Etudes des Systèmes Energétiques (EFESE), de EDF R&D, qui vise à permettre l'étude de la fiabilité de solutions alternatives au renforcement sur des réseaux [145].

Ces tables sont des tableaux à 4 dimensions, les dimensions étant associées à :

- La charge L1 dans la zone 1. Cette valeur va de 0% à 100%, avec un pas de 5%.
- La charge L2 dans la zone 2. Cette valeur va de 0% à 100%, avec un pas de 5%.
- La valeur de DLR utilisée  $\Delta_{s,0,t}$  lors des opérations de dispatch à l'instant t. Cette valeur va d'une valeur minimale  $\underline{\Delta}_1$ , ici 100%, à une valeur maximale  $\overline{\Delta}_1$ , ici 200%, avec un pas de 1%.
- La valeur de DLR potentiellement observée  $\Delta_{s,1}$  à l'instant t+h. Cette valeur va aussi de  $\underline{\Delta}_1$  à  $\overline{\Delta}_1$ , avec un pas de 1%.

Chaque terme de la table est un tuple de 5 variables qui comprend :

- Le coût global du système pour une valeur de DLR égale à  $\Delta_{s,1}$ .
- Les bénéfices associés à la prévision du DLR  $\Delta_{s,0,t}$ .
- La puissance allouée à l'allocation de réserve à la hausse pour la prévision du DLR  $\Delta_{s,0,t}$ , la valeur pour la puissance allouée à l'allocation de réserve à la baisse étant la même.
- Le coût de l'activation de la réserve à la hausse si le DLR observé est égal à  $\Delta_{s,1}$ .
- Le coût de l'activation de la réserve à la baisse si le DLR observé est égal à  $\Delta_{s,1}$ .

On trouve les valeurs de ces 5 variables de la manière suivante :

- Pour l'ensemble des valeurs de L1 possibles :
  - Pour l'ensemble des valeurs de L2 possibles :
    - Avec la valeur de DLR égale à  $\underline{\Delta}_1$ , l'algorithme de unit de-commitment est utilisé pour fixer les générateurs activés pour la suite de cette étape.
    - Pour toutes les valeurs de DLR possibles  $\Delta_1$ , un SCOPF est fait, et les valeurs de coûts globaux et les puissances générées par les générateurs sont enregistrées.
    - Pour une valeur de DLR prévu  $\Delta_{s,0,t}$  et de DLR observé  $\Delta_{s,1}$  :
      - les coûts globaux sont obtenus grâce au résultat du SCOPF fait avec la valeur  $\Delta_1 = \Delta_{s,0,t}$

- les bénéfices associés à la prévision du DLR  $\Delta_{s_0,l}$  sont calculés avec la différence des coûts globaux entre les SCOPF faits avec les valeurs de DLR  $\Delta_l = \Delta_{s_0,l}$  et  $\Delta_l = \underline{\Delta}_l$ .
- La puissance allouée à l'allocation de réserve à la hausse est obtenue en calculant les différences de puissance générées par les différents générateurs pour les SCOPF faits avec les valeurs de DLR  $\Delta_l = \Delta_{s_0,l}$  et  $\Delta_l = \underline{\Delta}_l$ .
- Le coût de la réserve à la hausse et à la baisse sont obtenus en calculant les différences de puissance générées par les différents générateurs pour les SCOPF faits avec les valeurs de DLR  $\Delta_l = \Delta_{s_0,l}$  et  $\Delta_l = \Delta_{s,l}$ .

Pour le calcul des différents termes, l'approche où les coûts des générateurs évoluent de manière linéaire avec les productions peut être problématique en raison de la non-unicité des solutions optimales permettant de réduire des coûts pour les SCOPF. Ainsi, des coûts de réserve peuvent apparaître, simplement car deux solutions optimales différentes ont été trouvées pour le même problème, entraînant des différences de niveau de puissances pour les générateurs du réseau. Cela peut être le cas par exemple si deux générateurs ayant un même coût unitaire de production sont localisés au même nœud, la somme des puissances des deux générateurs étant constante lors de la résolution d'un même problème deux fois, mais la répartition des puissances générées entre les deux générateurs variant et entraînant alors des coûts de réserve absurdes avec notre approche.

Afin d'imposer l'unicité des solutions aux problèmes de DCOPF, les données des coûts des générateurs ne sont pas fixées comme des fonctions linéaires, mais comme des fonctions quadratiques au terme d'ordre 2 négligeable.

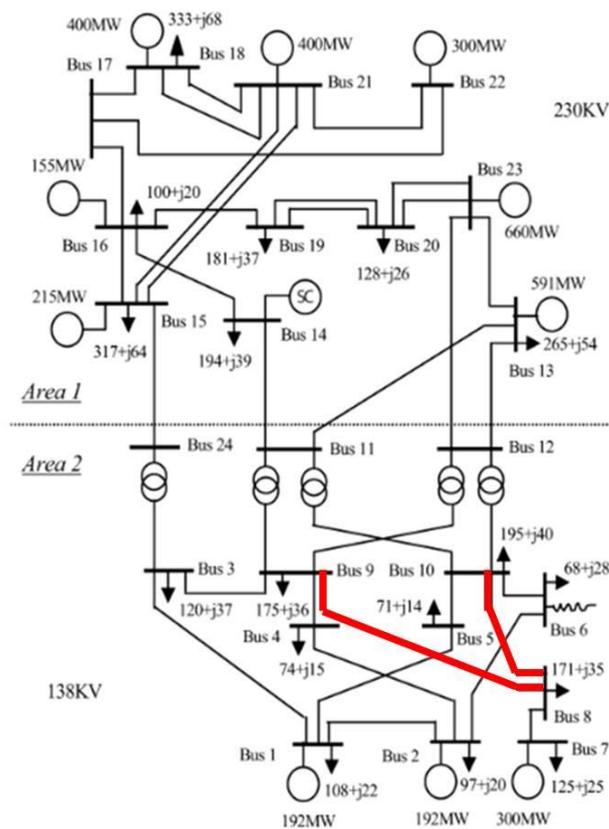
Par la suite, en combinant les résultats de cette table, et les données issues d'une prévision du DLR, il est possible d'obtenir une valeur de de prévision DLR  $\Delta$  optimale, ainsi que les bénéfices et le coût des erreurs attendus.

## 5.5. Cas d'étude

### 5.5.1. Description du réseau utilisé

Dans notre travail, nous avons choisi de travailler avec le réseau IEEE à 24 nœuds, décrit dans [146] (**Figure 5-1**).

Les coûts de réserve et d'allocation sont définis de manière similaire au cas défini dans [60] : les coûts d'allocation de réserve à la hausse et à la baisse sont fixés comme égaux à 6€/MWh pour tous les générateurs du réseau ; les coûts d'activation de réserve sont fixés comme égaux au prix du fuel pour le prix d'activation de la réserve à la baisse, et comme égaux à 150% du prix du fuel pour une activation à la hausse.



**Figure 5-1.** Réseau IEEE à 24 nœuds. En rouge, on surligne les lignes équipées de DLR en rouge.

Comme évoqué dans le chapitre 4, des calculs avaient été initialement faits pour observer l'impact du DLR sur la TTC entre deux zones 1 et 2. Nous avons pu remarquer alors que deux lignes apparaissaient comme des lignes congestionnées, les lignes 8-9 et 8-10, et nous les avons alors considérées comme équipées avec le DLR. A noter que ces deux lignes ont la même valeur de RTLRL à chaque instant, en raison de leurs caractéristiques identiques laissant penser qu'elles suivent le même itinéraire géographique (les caractéristiques d'impédance sont par exemple identiques).

Sur ce réseau, on considère pour générer des contraintes N-1 que des incidents peuvent se produire sur l'ensemble des lignes, à l'exception de la ligne 7-8, celle-ci connectant le bus 7 au reste du réseau de manière radiale et sa désactivation isolant le bus 7 du reste du réseau.

Pour ces lignes, on fixe dans un premier temps une valeur de DLR maximal pour les lignes équipées du DLR égale à 200% du SLR. La valeur minimale du DLR est égale à 100% du SLR, ici la valeur de l'ampacité définie dans les données du réseau IEEE.

### 5.5.2. Tables de correspondance obtenues

Pour le cas d'étude précédemment décrit et avec l'approche proposée en section 5.4, on représente sur la **Figure 5-2** les valeurs de DLR requises dans les lignes équipées pour lever les congestions, en fonction des niveaux de consommation L1 et L2 dans les deux zones.

		Consommation zone 1																						
		L <sub>min</sub>	0,0%	2,5%	7,5%	12,5%	17,5%	22,5%	27,5%	32,5%	37,5%	42,5%	47,5%	52,5%	57,5%	62,5%	67,5%	72,5%	77,5%	82,5%	87,5%	92,5%	97,5%	
		L <sub>max</sub>	2,5%	7,5%	12,5%	17,5%	22,5%	27,5%	32,5%	37,5%	42,5%	47,5%	52,5%	57,5%	62,5%	67,5%	72,5%	77,5%	82,5%	87,5%	92,5%	97,5%	100%	
Consommation zone 2	L <sub>min</sub>	L <sub>max</sub>																						
	0,0%	2,5%																						
	2,5%	7,5%																						
	7,5%	12,5%																						
	12,5%	17,5%																						
	17,5%	22,5%																						
	22,5%	27,5%																						
	27,5%	32,5%																						
	32,5%	37,5%																						
	37,5%	42,5%																						
	42,5%	47,5%																						
	47,5%	52,5%																						
	52,5%	57,5%																						
	57,5%	62,5%																						
	62,5%	67,5%																						
	67,5%	72,5%		105%																				
	72,5%	77,5%																						
77,5%	82,5%																							
82,5%	87,5%																							
87,5%	92,5%		110%	110%	110%	110%	110%	110%	110%	110%	110%	110%	110%	110%	110%	110%	110%							
92,5%	97,5%		118%	118%	118%	118%	118%	118%	118%	118%	118%	118%	118%	118%	118%							105%		
97,5%	100%		127%	127%	127%	127%	127%	127%	127%	127%	127%	127%	107%											

**Figure 5-2.** Valeur d’ampacité requise dans les lignes 8-9 et 8-10 pour lever les congestions dans ces lignes, en fonction des niveaux de consommations L1 et L2 dans les zones 1 et 2. Les cases blanches correspondent à de situations où après DCOPE, il n’y a pas de congestion, et les cases rouges aux situations où des congestions apparaissent dans les lignes équipées de DLR. Les valeurs d’ampacité requises pour lever les congestions sont normalisées par rapport aux valeurs de SLR.

Plusieurs points méritent d’être commentés. Tout d’abord, on évoquera ici la littérature relative au DLR, qui met régulièrement en avant les évolutions importantes possibles du DLR par rapport au SLR. Ainsi, dans le premier chapitre de cette thèse, on avait évoqué des valeurs de DLR pouvant atteindre jusqu’à 300% des valeurs du SLR. Or, comme on le voit ici, les valeurs d’ampacité requises pour lever les congestions sur les lignes équipées de DLR ne montent que jusque 127% de l’ampacité de la ligne.

La première raison à cela est le dimensionnement du réseau, fait pour un ensemble de situations tel que des situations où des congestions se produisent soit rares. Dans un tel contexte, il est difficile d’obtenir des situations où des évolutions d’ampacité importantes sont requises.

Une deuxième raison que nous avons déjà évoquée est la structure maillée du réseau : lors des études préliminaires que nous avons faites sur l’évolution de la TTC sur ce réseau, étude que nous avons évoqué dans le chapitre 4 avec la **Figure 4-2**, nous avons pu constater que la TTC évoluaient avec le DLR jusqu’à une valeur de 125% du SLR. A partir de cette valeur, la congestion sur le réseau passait de la ligne équipée vers une autre ligne en raison de la structure maillée du réseau. De telles structures sont aujourd’hui inexistantes pour les réseaux de distribution qui sont encore opérées de manière radiale, mais elles sont fréquentes pour les réseaux de transport pour lesquels le DLR est aujourd’hui principalement utilisé.

Ensuite, on note que sur la **Figure 5-2**, les « zones » où des congestions se produisent ont une forme contre-intuitive. Quelques exemples pour illustrer ces points :

- Pour un niveau de charge dans la zone 1 compris entre 57,5% et 62,5% de la valeur nominale de la charge, des congestions apparaissent pour un niveau de charge dans la zone 2 devenant supérieur à 87,5%. Là où on pourrait s'attendre à ce que le DLR reste utile lorsque le différentiel de consommation entre les deux zones augmente, on note que ces congestions disparaissent pour un niveau de charge dans la zone 2 devenant supérieur à 97,5%.
- On remarque des zones de congestion isolées, comme par exemple pour des niveaux de charge de 90% en zone 1 et de 95% en zone 2.

Ces résultats sont dus aux variations importantes de l'ensemble des générateurs activés, associé au vecteur  $I_g$  dans notre ensemble d'équations. Pour deux niveaux de charge proches, deux combinaisons de vecteurs  $I_g$  très différentes peuvent être obtenues. Ces différences entre ces deux combinaisons occasionnent alors des flux eux-mêmes différents dans les lignes équipées de DLR, ce qui occasionne des changements brusques sur le degré de possibilité d'utilisation du DLR.

Ces résultats nous poussent à prendre des précautions sur l'ensemble des études analysant les bénéfices du DLR sur des simulations de réseau et tenant compte de nombres entiers dans les problèmes d'optimisation stochastique : les résultats de l'évaluation des bénéfices du DLR sont extrêmement sensibles à la valeur de ces nombres, et ceux-ci peuvent varier fortement avec les niveaux de consommation.

Une première méthode pour éviter ces difficultés serait de ne plus considérer une optimisation stochastique pour un instant donné, mais plutôt pour une durée donnée, une valeur de  $I_g$  associée à un ensemble de points et tenant compte de contraintes comme des rampes d'activation pouvant alors permettre d'éviter de telles variations. Une deuxième solution serait de fixer le vecteur  $I_g$ , en le considérant comme défini à l'avance par le gestionnaire de réseau, de tels scénarios étant déjà définis par les GRT pour les définitions de capacité d'échange en J-1. Dans ce travail, nous n'avons pas résolu ce problème, et pour la réalisation de nos tables, le *unit commitment* proposé n'a pas été modifié.

### 5.5.3. Cas d'étude 1 : séries temporelles réelles

Bien que les lignes 8-10 et 8-9, équipées de DLR, n'apparaissent pas comme localisées à la frontière des deux marchés, celles-ci connectant deux points de la zone 2, nous avons considéré que la valeur d'ampacité de ces lignes était pour un premier cas d'étude comme liée à des données météorologiques collectées par Météo France près de la frontière franco-belge, à la position de l'aéroport de Lille (50,375°N ; 3,125°E).

Pour la période considérée, nous avons pris en compte un ensemble de points associés à une période considérée comme hivernale, allant du 1 novembre 2014 au 30 mars 2015, avec des observations faites toutes les heures. Cette période a été choisie de manière à pouvoir considérer les valeurs de SLR sur l'ensemble des lignes comme non variables et toujours égales aux valeurs d'ampacité fournies dans la description du réseau IEEE, en raison du fait que l'on pouvait considérer qu'il n'y avait pas de changement de saisons sur une période de 5 mois, trois mois étant en hiver et deux étant accolés à la saison.

Pour les calculs de RTLRL avec les observations météorologiques, nous avons posé que les caractéristiques de ces lignes étaient celles d'un câble Lynx 175 mm<sup>2</sup>, déjà utilisé dans le chapitre 2 pour calculer des valeurs de RTLRL, et nous avons par la suite normalisé les valeurs de DLR par rapport à une

valeur de SLR. La valeur du SLR prise pour la normalisation est la valeur de 651A utilisée par NIE pour le même câble pour la période hivernale [27]. Avec les observations DLR, nous observons que le RTLRL est inférieur à la valeur du SLR que nous utilisons dans 6,6% des cas. Si nous voulions réduire cette fréquence à 1,0%, une valeur de SLR de 507A aurait dû être définie. Les prévisions utilisées sont les mêmes que celles du chapitre 4.

Deux séries temporelles ont été considérées pour des profils de charges, définis pour les zones 1 et 2. Les profils de charge sont les mêmes que ceux considérés au chapitre 4, basé sur les historiques de la consommation française et la consommation belge pour la période 2014-2015, fournis par BELPEX et EPEX. Les valeurs sont normalisées par rapport aux maximums de consommation observés pour les périodes considérées.

Dans un état où les charges maximales ne sont pas modifiées et sont égales aux puissances consommées fournies dans la description du réseau IEEE, nous trouvons une proportion de situations relativement faible où le DLR serait en mesure d'apporter des bénéfices, seulement 24 telles situations étant observées : le réseau a été dimensionné de manière à pouvoir supporter l'ensemble des scénarios de consommation, et dans ce contexte nous observons des congestions seulement quand la consommation dans la zone 1 est supérieure à 100% de la valeur nominale. Afin d'obtenir un nombre d'observations plus important où le DLR est utilisé, nous avons augmenté l'ensemble des valeurs de consommation de 30%, ce qui permet alors d'avoir 187 observations qui sont associées à des situations où le DLR peut lever des congestions.

Les résultats obtenus avec ce cas d'étude sont présentés dans la section 5.6.

#### **5.5.4. Cas d'étude 2 : séries générées par bootstrap**

Dans le cas d'étude 1, parmi l'ensemble des observations de consommation considérées (L1,L2), une faible proportion de situations permettait d'obtenir des phénomènes de congestion avec le réseau électrique considéré.

Ici, nous proposons de générer par bootstrap de nouvelles séries de consommation, de manière à ce que l'ensemble des observations entraînent des situations de congestion. Cette opération consiste à générer une série à partir de tirages aléatoires dans un ensemble de couples de charge pour lesquels il y a congestion.

Dans le cas d'étude 1, nous avons considéré des données en provenance de France et de Belgique. Dans ce cas d'étude 2, nous avons préféré travailler avec des ensembles de données associés à la France et à l'Allemagne. En effet, en utilisant des données de consommation horaires fournies par ENTSO-E pour l'année 2010 [147] ainsi que les tables de correspondance présentées en 0, nous avons pu constater après avoir testé plusieurs couples de pays que ce couple permettait d'obtenir un nombre de situations où des congestions se produisaient important. Ainsi, avec ce couple, 4.1% des observations de consommation sur l'année 2010 entraînent des phénomènes de congestion sur les lignes équipées de DLR dans le réseau IEEE, là où pour des couples liant la France et la Belgique ou l'Irlande du Nord et l'Irlande, ces fréquences sont inférieures à 2%.

Les résultats pour différents couples de pays sont illustrés sur le tableau 5-1.

**Tableau 5-1.** Exemples de couples de pays considérés pour générer les courbes de consommation et fréquence des situations entraînant des congestions sur les ligne équipées de DLR dans le réseau IEEE étudié.

Z1 country	Z2 country	Frequency of situations where congestions occur in 2010 (%)
Northern Ireland	Ireland	0,4
Ireland	Northern Ireland	0,9
France	Germany	4,1
Germany	France	1,6
France	Spain	3,9
Spain	France	1,9
France	Belgium	1,8
Belgium	France	1,6
Netherland	Germany	2,3
Germany	Netherlands	3,6
Germany	Poland	3,4
Poland	Germany	2,4

Avec ces cas d'étude, nous chercherons à comparer des modèles de prévision du DLR différents, et les prévisions DLR utilisées sont maintenant celles développées au chapitre 2 et au chapitre 3, des prévisions faites pour l'année 2010 pour des stations météorologiques localisées au Royaume-Uni. Pour deux modèles de prévisions faits pour la même station et la même période, une même série générée par bootstrap est utilisée avec les deux modèles de prévision.

Contrairement au cas d'étude 1, des prévisions sont considérées pour une année entière, et donc 4 saisons différentes qui nécessitent des définitions de valeurs de SLR différentes pour chaque saison. Dans le cas d'étude 2, chacune de ces valeurs de SLR est définie à l'aide des observations DLR pour l'ensemble des observations, de manière à rester inférieure au RTLR 99% du temps. Sur le **Tableau 5-2**, on montre les valeurs de SLR obtenues pour la station 1.

Pour deux séries de prévisions faites avec des modèles différents mais pour les mêmes séries temporelles, nous utilisons la même série de scénarios de charge qui a été générée par bootstrap.

**Tableau 5-2.** Valeurs de SLR utilisées pour générer les valeurs d'ampacité, définies de telle manière à être supérieures aux observations du RTLR 1% du temps.

	SLR_1% (A)
Hiver	483
Automne/Printemps	476
Eté	451

### 5.5.5. Différences de calcul pour les deux cas d'étude

Pour les deux cas d'étude, les calculs ayant été faits à des périodes de la thèse différentes où les modèles utilisés étaient avancés à différents stades, les méthodes de calculs varient sur certains points.

Dans le cas 1, il n'y a pas eu de *unit commitment* fait, l'ensemble des générateurs étant considérés comme activés. De plus, les résultats étaient obtenus à partir d'interpolations linéaires entre les différents points de la table de correspondance, en fonction des valeurs de charge.

Pour les séries générées par bootstrap du cas 2, le *unit commitment* proposé a été fait. L'ensemble des valeurs de charges ont été arrondies aux valeurs de charge considérées dans la table, des interpolations ne nous apparaissant pas raisonnables. En effet, pour deux scénarios de consommation adjacents, la configuration des générateurs activés obtenus par *unit commitment* pouvait fortement varier, rendant alors difficile de poser l'hypothèse d'une continuité des valeurs fournies par la table en fonction des valeurs de charge.

## 5.6. Résultats pour le cas 1

### 5.6.1. Evaluation de la stratégie neutre au risque

Nous avons souhaité à partir de la méthodologie proposée dans la section 5.3 évaluer plusieurs stratégies différentes. Dans un premier temps, nous avons pris en compte trois stratégies :

- On utilise un quantile arbitraire  $\tau$  sélectionné et fixé sur l'année, égal à 1%.
- On utilise un quantile  $\tau_{opt}$  sélectionné et fixé sur l'année de manière à maximiser les bénéfices économiques observés. Ce quantile  $\tau_{opt}$  est égal à 26,5%.
- La valeur de la prévision du DLR est fixée de manière à ce que pour chaque prévision, les bénéfices économiques attendus soient maximisés.

Les réductions de coûts du système attendues et observées sont calculées pour la période considérée, et sont illustrées sur le **Tableau 5-3**. Nous avons ici préféré utiliser ces améliorations à l'aide de la notion de bénéfices, ceux-ci étant calculés dans tout ce chapitre comme la différence entre les coûts du système pour une période donnée lorsque le SLR est utilisé,  $L^{SLR}$ , et les coûts du système pour la même période lorsque le DLR a été utilisé,  $L^{DLR}$ . Dans tout ce chapitre, cette différence est ensuite normalisée par rapport à  $L^{SLR}$ .

$$\text{Benefice}^{DLR} = \frac{L^{SLR} - L^{DLR}}{L^{SLR}} \cdot 100\% \quad (5-48)$$

Le fait d'utiliser une telle formulation permet une comparaison rapide des différentes stratégies entre elles, le ratio entre les bénéfices de différentes stratégies étant calculé aisément. De plus, il est possible de directement calculer le ratio entre les bénéfices observés et les bénéfices attendus pour vérifier si le modèle de prévision est adapté et si les prévisions des bénéfices attendus sont correctes, là où un tel ratio serait difficile à analyser en utilisant seulement les coûts de productions totaux.

En plus de ces bénéfices, nous ajoutons une évaluation des pénalités financières et des risques assumés par le gestionnaire de réseau à l'aide de trois indices :

- La fréquence à laquelle des activations de réserve sont requises de la part du gestionnaire de réseau.
- Le coût total des opérations d'activation de réserve sur la période considérée. Dans tout ce chapitre, cette valeur est aussi normalisée en étant divisé par la valeur  $L^{SLR}$  obtenue pour chaque cas d'étude.

- La fréquence des erreurs importantes, ici arbitrairement définies comme les erreurs impliquant des activations de réserve au coût supérieur à 60€.

**Tableau 5-3.** Comparaison de stratégies : bénéfices attendus, bénéfices observés, fréquence d'activation de réserve, coût total de la réserve, fréquence des situations entraînant des coûts de réserve supérieurs à 60€.

	Utilisation de quantiles fixés à 1%	Utilisation de quantiles fixés à 26,5%	Utilisation d'une approche optimisant les bénéfices, sans aversion au risque	Utilisation d'une prévision parfaite
Bénéfices attendus (%)	$0,49 \cdot 10^{-2}$	$5,19 \cdot 10^{-2}$	$6,44 \cdot 10^{-2}$	-
Bénéfices observés (%)	$0,44 \cdot 10^{-2}$	$5,93 \cdot 10^{-2}$	$7,15 \cdot 10^{-2}$	$9,53 \cdot 10^{-2}$
Coût total des activations de réserve (%)	$0,26 \cdot 10^{-4}$	$10,32 \cdot 10^{-4}$	$9,77 \cdot 10^{-4}$	$0,00 \cdot 10^{-4}$
Fréquence de situations nécessitant une activation de réserve (%)	0,08	1,12	0,83	0,00
Fréquence des situations nécessitant une activation de réserve au coût supérieur à 60€ (%)	0,00	0,60	0,58	0,00

Plusieurs résultats sont à remarquer. Tout d'abord, des différences de l'ordre de 10 à 20% sont observées entre les résultats attendus et les résultats observés. Cette différence est suffisamment faible pour que par la suite, on considère que les bénéfices économiques observés soient similaires à ceux qui auraient été attendus de la part du gestionnaire de réseau. Surtout, pour le cas d'étude 2, ces différences seront abaissées à moins de 1%, le nombre de congestions considérées étant très supérieur, passant de 200 pour le cas 1 à près de 8000 pour le cas 2.

On remarque aussi que l'utilisation de prévisions optimisées apporte des bénéfices significatifs par rapport à l'utilisation de quantiles fixes, les bénéfices augmentant de 20%, passant de  $5,93 \cdot 10^{-2} \%$  à  $7,15 \cdot 10^{-2} \%$ , et les coûts totaux des erreurs de prévision étant abaissés de près de 5%, passant de  $10,32 \cdot 10^{-4} \%$  à  $9,77 \cdot 10^{-4} \%$ . L'évolution des fréquences d'erreur est-elle beaucoup plus importante, égale à 26%, passant de 1,12% à 0,83%. Cela traduit une répartition différente des coûts des différentes opérations. Par exemple, avec la stratégie à quantiles fixes, 13 erreurs ont un coût inférieur à 1€, là où seulement 4 sont observées avec l'utilisation d'une optimisation neutre au risque.

En passant de l'utilisation du quantile 1% à l'utilisation du quantile 26,5%, nous avons été en mesure de multiplier les bénéfices par un facteur proche de 16. Cette évolution semble importante, mais pour les 187 observations, on constate que dans 4 cas des surestimations de prévisions se produisent lorsque des quantiles à 1% sont utilisés, là où ce nombre de surestimations devrait être inférieur à 2. Les performances de la stratégie utilisant des quantiles à 1% étant pénalisée en raison d'une mauvaise calibration sur le faible ensemble de points, il devient difficile de généraliser ces résultats.

Les augmentations de bénéfices s'accompagnent par une augmentation très importante des coûts pour le gestionnaire de réseau, les coûts d'activation de réserve étant multiplié par plus de 10, et le nombre d'opérations d'activations de réserve étant multiplié par près de 4.

Ces rapports d'évolution des coûts de réserve et les résultats évoqués sont similaires à ceux que l'on avait vu dans le chapitre 4, dans la section 4.6. On trouve en revanche en complément deux résultats qui diffèrent de manière significative.

Dans un premier temps le quantile  $\tau_{arb\ opt}$  obtenu est important, égal à 26,5%, beaucoup plus important que le quantile de 9% obtenu dans le chapitre 4. Cette valeur dépend en grande partie des coûts de réserve utilisés, qui sont inférieurs à ceux utilisés dans le chapitre 4.

Ensuite, dans le chapitre 4, on a évoqué des rapports entre les bénéfices attendus pour la gestion du réseau et les coûts pour le gestionnaire de réseau qui pouvait aller jusqu'à 2 dans le cas de l'obtention du niveau de bénéfices maximum. Ici, ceux-ci sont de l'ordre de 20 pour l'obtention du même niveau de bénéfice, traduisant ainsi un coût très réduit de l'amélioration des opérations de dispatch neutres au risque pour le gestionnaire de réseau.

Cela est dû au fait que la structure du réseau étant désormais prise en compte, le problème est alors différent dans le sens où seule une petite portion de l'amélioration d'ampacité apportée par le DLR peut être utilisée lors des opérations de dispatch. Ce point est important et représente une différence significative entre l'utilisation de prévisions du DLR et de prévisions faites pour les énergies renouvelables. Sauf cas rares comme par exemple lors d'événements d'effacement de production, la totalité de l'énergie produite par un producteur EnR est utilisée, et nous avons repris une telle hypothèse dans le chapitre 4. Cependant, on remarque pour ce cas d'étude que seule une faible proportion du DLR offerte est exploitée, posant alors une limite maximale à la valeur du DLR variant entre 100% et 120% du SLR, en fonction des niveaux de charge considérés pour les deux zones.

Au vu de ce rapport important entre les gains et les pertes du TSO, il peut alors être possible de considérer que le gestionnaire de réseau peut accepter désormais une approche neutre au risque, le rapport entre ses pertes et les gains pour l'ensemble du réseau étant important. On peut en revanche considérer les fréquences des erreurs ayant un coût supérieur à un seuil donné, des situations où les prix d'activation de réserve sont importants ou où les magnitudes des erreurs de prévision sont importantes. Là où pour des quantiles à 1%, pour un seuil de 60€, ces erreurs sont inexistantes, elles représentent près de la moitié des erreurs observées pour les deux autres stratégies. On pourrait considérer qu'il soit souhaité que la fréquence de tels dépassements soit limitée pour le gestionnaire de réseau, et ainsi, l'utilisation de stratégies averses au risque pourraient être souhaitée.

### 5.6.2. Evaluation des stratégies averses au risque

Pour nos études, que ce soit avec le cas d'étude 1 ou 2, et pour chaque fonction  $v_\beta$ , on considère une suite de valeurs de  $\beta$  calculée de manière itératives, le premier terme  $\beta_0$  étant égal à 0, et pour  $k > 0$ , le  $k^{\circ}$  terme de la suite  $\beta_k$  à l'aide de la suite suivante :

$$\beta_k = 10^{\frac{k-\alpha}{\gamma}} \quad (5-49)$$

De manière générale pour nos cas d'étude, on définit les termes  $\alpha$ ,  $\gamma$  et le maximum d'éléments de la liste de telle manière que pour les 5 premiers éléments de la liste, et les 5 derniers, les bénéfices attendus varient de moins d'une valeur seuil donnée, la valeur  $10^{-8}\%$  étant utilisée dans nos calculs. Généralement, nous avons fixé  $\alpha$  et  $\gamma$  de manière à ce que près de 200 itérations soient nécessaires pour aller de  $\beta_0$  à  $\beta_{Max}$ . En reprenant ces chiffres, on comprend à nouveau la difficulté que nous aurions eue si des méthodes d'optimisation avaient été utilisées plutôt que les tables de correspondance que nous avons créées, 1,75 millions de simulations étant par exemple nécessaire pour l'étude d'une seule stratégie utilisée sur un an de données.

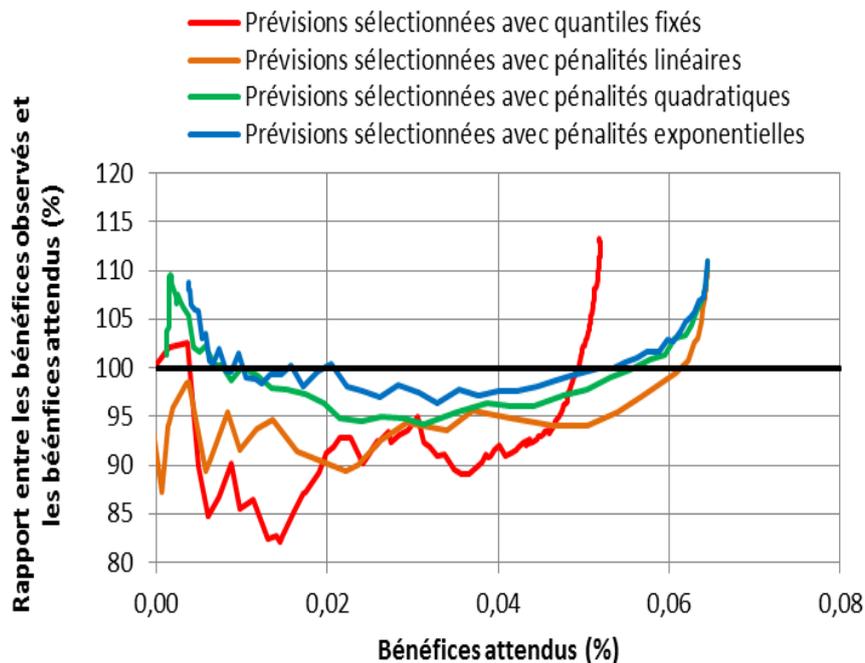
Pour chaque valeur de  $\beta$ , les données suivantes sont obtenues :

- Les bénéfices moyens attendus pour l'année étudiée après l'utilisation des tables de correspondance, en fonction des données de consommation et des prévisions DLR pour cette année.
- Les bénéfices moyens observés pour l'année étudiée, obtenus avec les mêmes données que le point précédent et les observations DLR.
- Le nombre de situations où les observations DLR sont inférieures aux prévisions choisies.
- Les coûts des erreurs de prévisions DLR obtenus.
- Le nombre de situations où des erreurs de prévisions ont un coût supérieur à un seuil donné.

### 5.6.2.1. Rapport entre les bénéfices attendus et les bénéfices observés

Dans les prochaines sections on considère régulièrement que les valeurs de  $\beta$  utilisées pour la définition de  $v_\beta$  correspondent à des opérations où les niveaux de bénéfices attendus et observés sont égaux.

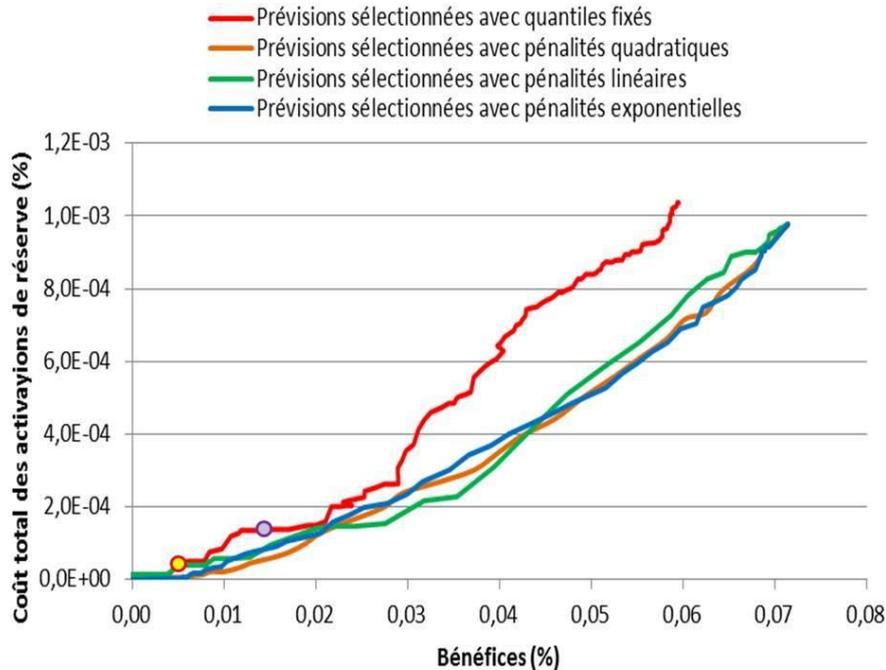
Une vérification de cette hypothèse est faite sur la **Figure 5-3**. Comme on peut le voir, les ratios varient entre 80% et 120%. On peut considérer que ces valeurs sont médiocres, et ils sont en grande partie du au faible nombre de points réellement utilisés dans les séries temporelles pour évaluer des améliorations possibles dues à des prévisions DLR. Comme déjà dit précédemment, ce point est corrigé pour le cas d'étude 2, le nombre de simulations où des congestions se produisent étant très fortement augmenté (on passe de 187 situations de congestion à plus de 8000).



**Figure 5-3.** En fonction des différentes stratégies utilisées, évolution des bénéfices obtenus par rapport aux bénéfices attendus.

Les bénéfices attendus et observés étant proches, il est possible par la suite de faire des études en posant que le gestionnaire de réseau aurait pu définir les paramètres de la fonction  $v_\beta$  de manière à s'attendre aux bénéfices observés.

Chacune des trois fonctions de perte utilisées dépendant d'un paramètre  $\beta$ , comme proposé en introduction de cette section, on fait évoluer cette valeur de manière itérative  $\beta_0$  à  $\beta_{Max}$  et on mesure l'évolution des coûts pour le gestionnaire de réseau fonction des bénéfices en termes de réduction des coûts du système pour l'année étudiée. On représente sur la **Figure 5-4** cette évolution pour les quatre stratégies considérées.



**Figure 5-4.** Evolution des coûts de réserve en fonction des bénéfices observés et de la stratégie de sélection du DLR. Le point jaune correspond au résultat lié à l'utilisation de quantiles fixés à 1%, et le point violet à l'utilisation de quantiles fixés à 3%.

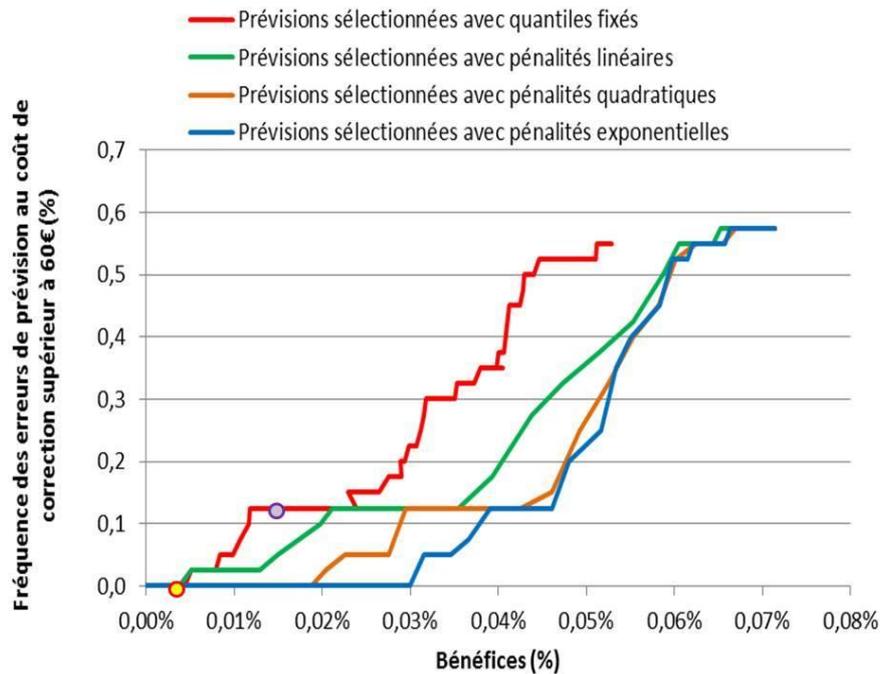
Pour l'ensemble des niveaux de bénéfices considérés, on note des améliorations permises par les stratégies considérées pour les coûts du gestionnaire de réseau : pour le même niveau de bénéfice, les stratégies permettent de réduire de manière significative les coûts pour le gestionnaire de réseau.

Les bénéfices sont ici difficiles à analyser pour des niveaux de bénéfices faibles, inférieurs à 0,005% et correspondant à l'utilisation de quantiles fixés à 1% et en-dessous, les pertes pour le gestionnaire de réseau s'annulent pour ces niveaux de bénéfices.

En revanche, pour des niveaux de bénéfices supérieurs, comme par exemple 0,0137% qui correspond aux bénéfices observés lors de l'utilisation de prévisions à quantile fixé à 3%, il est visible que l'utilisation des trois stratégies permet de réduire le coût de l'activation de la réserve de manière significative, de l'ordre de 30 à 60%. Ces résultats sont ensuite d'autant plus marqués que les niveaux de bénéfices augmentent.

Comme on l'a évoqué précédemment, il peut être nécessaire de s'intéresser à la fréquence des situations où les coûts de correction sont importants, les coûts totaux de réserve étant faibles par rapport aux bénéfices potentiels et ceux-ci pouvant ne pas alors être la variable déterminante pour les gestionnaires de réseau. Ce type de situation peut être en lien avec des situations à risque pour le gestionnaire de réseau, étant associé à des situations où les erreurs de prévisions sont importantes ou où l'activation de réserve est coûteuse et potentiellement compliquée. On représente alors sur la **Figure 5-5** l'évolution

de la fréquence des situations où des erreurs nécessitant des opérations ayant un coût supérieur à 60€ se produisent.



**Figure 5-5.** Evolution des fréquences de situations où des activations de réserve au coût supérieur à 60€ sont nécessaires, en fonction des bénéfices. Le point jaune correspond au résultat lié à l'utilisation de quantiles fixés à 1%, et le point violet à l'utilisation de quantiles fixés à 3%.

Comme sur la **Figure 5-4**, on note des améliorations permises par la mise en place des différentes stratégies. Plus la stratégie est contraignante pour les erreurs de magnitudes importantes, la stratégie des pénalités exponentielles étant la plus contraignante, plus la fréquence des erreurs de magnitude importantes décroît. On note aussi l'apparition de plusieurs plateaux, ceux-ci étant dus au faible nombre de points où des congestions se produisent.

Tous les résultats proposés ici sont encourageants, mais ils sont difficiles à exploiter en raison de la nature du cas d'étude pour lequel un très faible nombre de points est exploité. Celui-ci a été défini de manière à exploiter des séries temporelles de charge et de valeurs de DLR associées aux mêmes périodes. Cette approche aurait pu avoir le mérite de permettre d'étudier des phénomènes de corrélation, et on a pu obtenir de relativement bons résultats, mais il est impossible d'en tirer des conclusions pouvant être généralisables. Cela a motivé l'approche dont les résultats sont présentés dans la partie suivante, où des séries temporelles sont créées de manière à passer de près d'une centaine d'épisodes où des congestions se produisent à plusieurs milliers.

## 5.7. Résultats pour le cas 2

### 5.7.1. Utilisation de stratégies neutres au risque

On reprend ici le même type de tableau que le **Tableau 5-3**, ce afin de comparer des utilisations de quantiles différents et d'une utilisation d'une optimisation neutre au risque. En plus du quantile 1%, on

considère aussi le quantile 0,1%. Le quantile  $\tau_{arb\ opt}$  qui permet de maximiser les bénéfices attendus sur une année est égal à 19,6%.

Pour les valeurs de coûts correspondant à des incidents que l'on considère comme importants, le cas d'étude 2 différant du cas d'étude 1 en raison du fait que la valeur de SLR est maintenant définie avec des critères statistiques, qu'il y a un *unit commitment* fait et une utilisation de la table de correspondance différente, on définit ces seuils de coût comme égaux à 1000€ et 1500€.

**Tableau 5-4.** Comparaison de stratégies : bénéfices attendus, bénéfices observés, fréquence d'activation de réserve, coût total de la réserve, fréquence des situations entraînant des coûts de réserve supérieurs à 1000€ et 1500€.

	Utilisation de quantiles fixés à 0,1%	Utilisation de quantiles fixés à 1%	Utilisation de quantiles fixés à 19,6%	Utilisation d'une approche optimisant les bénéfices, sans aversion au risque	Utilisation de prévisions parfaites
Bénéfices attendus (%)	0,33	0,58	0,94	0,98	-
Bénéfices observés (%)	0,32	0,57	0,95	1,01	1,09
Coût total des activations de réserve (%)	0,004	0,010	0,135	0,108	0,000
Fréquence de situations nécessitant une activation de réserve (%)	0,23	0,61	5,27	4,52	0,00
Fréquence des situations nécessitant une activation de réserve au coût supérieur à 1000€ (%)	0,04	0,10	2,73	2,24	0,00
Fréquence des situations nécessitant une activation de réserve au coût supérieur à 1500€ (%)	0,04	0,09	1,59	1,35	0,00

Pour le cas d'étude 2, les niveaux de bénéfices pour l'optimisation neutre au risque sont très augmentés par rapport au cas d'étude 1, étant multipliés par 15 en passant de 0,07% à 1,01% du coût total des opérations, cela principalement en raison du fait que tous les points utilisés correspondent maintenant à des situations où le DLR est utile pour lever des congestions. Cette valeur de réduction des coûts d'opération apparaît raisonnable lorsque mise en lien avec des résultats trouvés dans [51], où pour un réseau IEEE à 30 nœuds des bénéfices variant entre 0,3% et 1% sont observés lorsque des prévisions DLR sont utilisées pour lever des congestions.

Par rapport au **Tableau 5-3**, on remarque une évolution importante des ratios traduisant les évolutions permises par les différentes stratégies. Là où avant un rapport proche de 15 était observé entre les bénéfices associés à une utilisation de quantiles élevés par rapport à une utilisation de quantiles fixés à 1%, on voit ce ratio ici descendre à 1,7. Le résultat tiré précédemment sur une évolution des bénéfices importante était donc surestimé, et était dû au faible nombre de points considérés et à une mauvaise fiabilité pour les faibles quantiles réduisant fortement les bénéfices des stratégies à quantile fixés. Pour rappel, pour l'ensemble des situations dans le cas 1 qui entraînait des situations de congestions, nous avons montré que dans 2% des cas, l'utilisation de prévisions quantiles à 1% avec le modèle utilisé entraînait des erreurs de prévision du DLR.

Ensuite, là où les bénéfices sont multipliés par un facteur de 1,7 relativement faible, la fréquence de prévisions surestimées est, elle, multipliée par 8 lors du passage de l'utilisation du quantile 1% au quantile 19,6%, passant de 0,61% à 5,27%, et les coûts totaux de réserve sont multipliés par 13, passant de 0,010% à 0,135%. Cette évolution est encore plus importante pour les erreurs au coût élevé, supérieur à 1500€, cette fréquence passant de 0,09% à 1,59% et étant alors multipliée par 18. Comme pour le cas d'étude 1, une augmentation des bénéfices se traduit par une explosion des indices pour lesquels le gestionnaire de réseau éprouve de l'aversion.

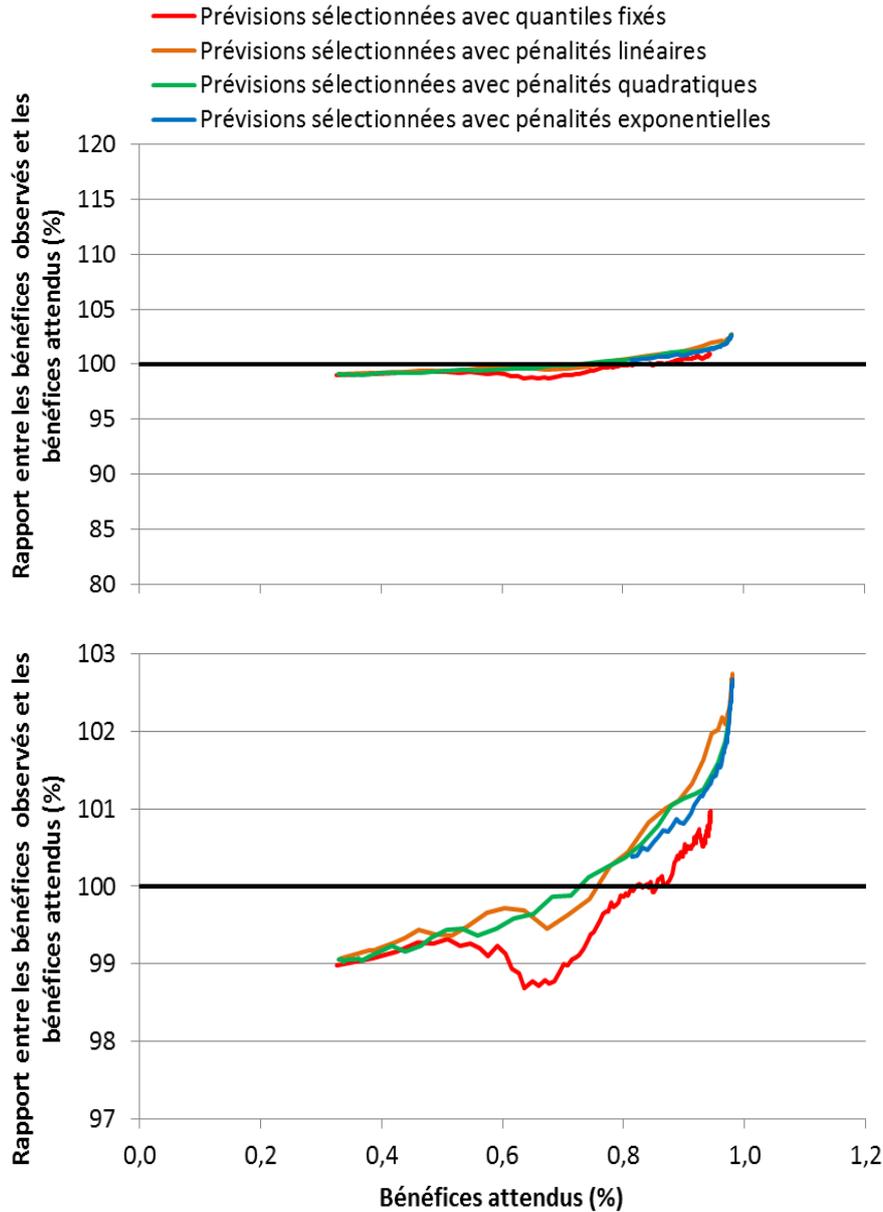
On note aussi que l'utilisation d'une méthode neutre au risque optimisant la valeur de la prévision du DLR offre de meilleures performances que l'utilisation de quantiles fixes élevés, les bénéfices étant augmentés de 6%, passant de 0,95% à 1,01%, et les coûts de réserve étant réduits de 20%, passant de 0,135% à 0,108%. Cependant, par rapport à l'utilisation de quantiles bas, les mêmes problèmes d'augmentation très forte des indices de risque subsistent que lors de l'utilisation de quantiles élevés fixes, le rapport entre les coûts de réserve associés à cette stratégie (0,108%) et les coûts de réserve associés à l'utilisation du quantile 1% (0,010%) étant par exemple de 11.

Enfin, il est intéressant de noter que des résultats intéressants semblent être associés à l'utilisation de quantiles fixes extrêmes, ici 0,1%. On conserve un niveau de bénéfice satisfaisant, égal à 0,33%. Le modèle de prévision utilisé est cependant un QRF non modifié comme cela est proposé dans le chapitre 3, et ce dernier résultat est à prendre avec précaution. Une discussion plus approfondie sur l'utilisation de quantiles très faible est faite dans la section 5.7.4.

### 5.7.2. Utilisation de fonctions de pertes différentes

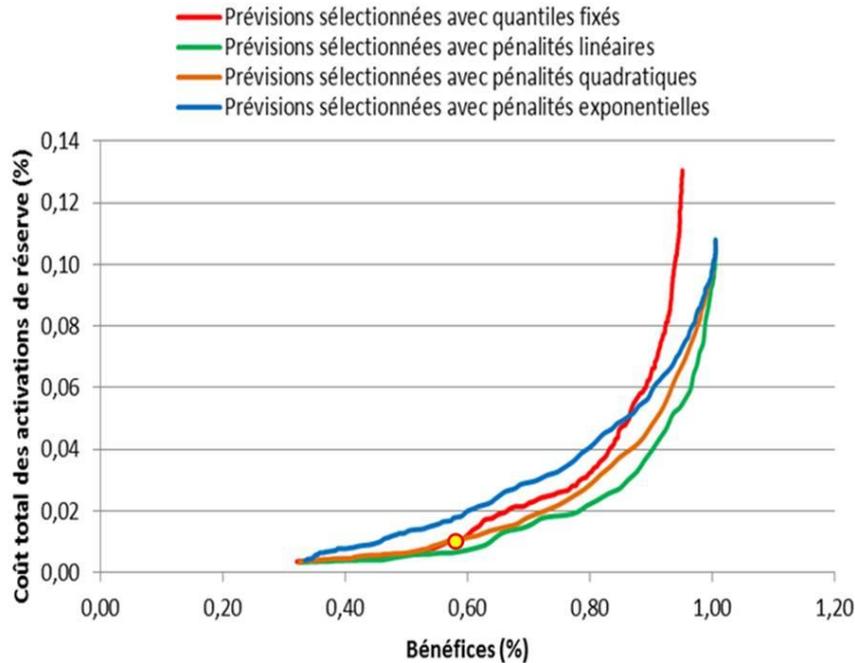
On représente sur la **Figure 5-6** l'évolution des bénéfices économiques observés en fonction des bénéfices économiques attendus, en considérant différentes fonctions  $v_\beta$  pour des valeurs de  $\beta$  évoluant comme proposé dans la section 5.6.2, ainsi que des prévisions faites avec un modèle QRF entraîné avec des fenêtres glissantes de 6 mois réactualisées tous les mois, ce modèle étant le même que celui utilisé au chapitre 3.

Contrairement au cas d'étude 1, où peu de points étaient considérés et où les rapports variaient entre 80% et 120%, on est ici en mesure d'obtenir des rapports beaucoup plus proches de 1, variant entre 99% et 102%. On pourra alors par la suite poser que la sélection d'un paramètre  $\beta$  donnera des performances similaires pour les bénéfices observés et les bénéfices attendus, permettant alors une sélection de ce paramètre en avance.



**Figure 5-6.** En fonction des différentes stratégies utilisées, évolution des bénéfices obtenus par rapport aux bénéfices attendus. Sur la figure du haut, pour les ordonnées, la même échelle que sur la **Figure 5-3** est utilisée.

On considère comme dans la section 5.6 l'évolution du coût de réserve associé aux erreurs de prévisions, en fonction des bénéfices. On représente ces évolutions sur la **Figure 5-7**.



**Figure 5-7.** Evolution des coûts de réserve en fonction des bénéfices observés et de la stratégie de sélection du DLR. Le point jaune correspond au résultat lié à l'utilisation de quantiles fixés à 1%.

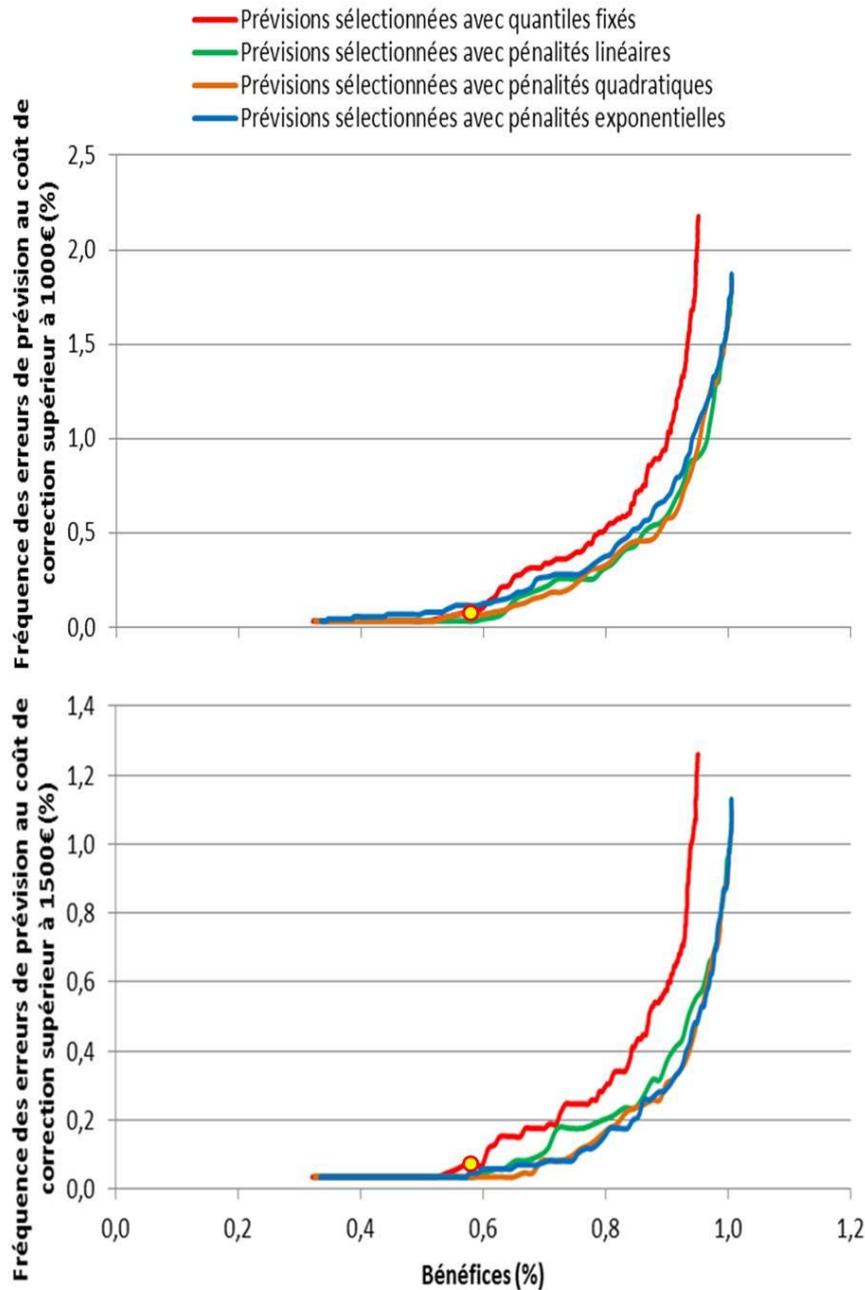
Plusieurs résultats sont à souligner. Tout d'abord, l'augmentation du nombre de points permet d'obtenir des courbes beaucoup plus lisses que celles obtenues pour le cas d'étude 1, les précédents résultats étant montrés sur la **Figure 5-4**.

Les évolutions des coûts pour les gestionnaires de réseau, pour des stratégies où  $\beta$  n'est pas nul, sont similaires à ce qui était observé dans la section 5.6, même s'il est à noter que les réductions possibles des coûts de réserve permises par les stratégies tendent à diminuer pour des niveaux de bénéfices faibles ( $<0,5\%$ ), les courbes associées aux utilisations de quantiles fixes et aux utilisations de pénalités linéaires et quadratiques étant alors accolées. Ainsi, pour des niveaux de bénéfices de 0,57% et un coût de réserve total égal à 0,010%, correspondant à l'utilisation de quantiles fixés à 1%, l'utilisation de pénalités linéaires permet pour le même niveau de bénéfice d'abaisser les coûts de réserve totaux à 0,006%.

On constate aussi que l'utilisation de pénalités quadratiques et exponentielles fournit des performances moindres par rapport aux pénalités linéaires pour la réduction des coûts totaux de réserve, les pénalités exponentielles étant mêmes moins efficaces que les stratégies à quantiles fixes pour des niveaux de bénéfices inférieurs à 0,9% des coûts totaux du système.

Il y a aussi une impossibilité pour les courbes d'atteindre l'origine du graphique, un point où les bénéfices et les pertes sont nuls. Cela est dû au comment la valeur de SLR a été définie dans le cas d'étude 2. Pour rappel, dans le cas d'étude 1, la valeur de SLR était définie avec des critères météorologiques, et cette valeur était inférieure aux valeurs de RTL dans 6,6% des cas. Ici, la valeur de SLR est définie de manière statistique de sorte à respecter ce critère statistique et cela entraîne que là où dans le cas d'étude 1 les prévisions quantiles extrêmes n'étaient jamais supérieures au SLR défini, ce qui permettait d'obtenir des niveaux de bénéfices nuls, ici cela n'arrive pas car les prévisions DLR quantiles à 0,1% sont régulièrement supérieures au SLR.

Comme précédemment, on trace ensuite sur la **Figure 5-8.** . L'évolution des fréquences des situations où des erreurs de prévisions DLR au coût important se produisent, ici des coûts supérieurs à 1000 € et 1500 €.



**Figure 5-8.** Evolution des fréquences de situations où des activations de réserve au coût supérieur à 1000€ et 1500€ sont nécessaires, en fonction des bénéfices. Les points jaunes correspondent aux résultats liés à l'utilisation de quantiles fixés à 1%.

Bien que cela soit moins marqué que pour le cas d'étude avec les séries temporelles, on remarque à nouveau que là où les pénalités exponentielles et quadratiques étaient moins efficaces pour améliorer les coûts de réserve totaux que les pénalités linéaires, celles-ci réussissent à réduire plus efficacement le nombre de situations où des erreurs importantes se produisent, en particulier pour des erreurs de magnitude supérieure à 1500 €.

Par exemple, par rapport à l'utilisation de quantile fixé, pour un niveau de bénéfices fixé à 0,57% correspondant à l'utilisation de quantiles fixés à 1%, l'utilisation de pénalités quadratiques permet de diviser par 2 la fréquence des situations où des erreurs au coût supérieur à 1500€ se produisent, passant de 0,071% à 0,035%.

Les résultats sont relativement proches entre les fonctions de pénalité exponentielle et les fonctions de pénalité quadratiques, et on préférera alors dans la suite de ce chapitre la deuxième en raison de son meilleur impact sur les coûts de réserve totaux.

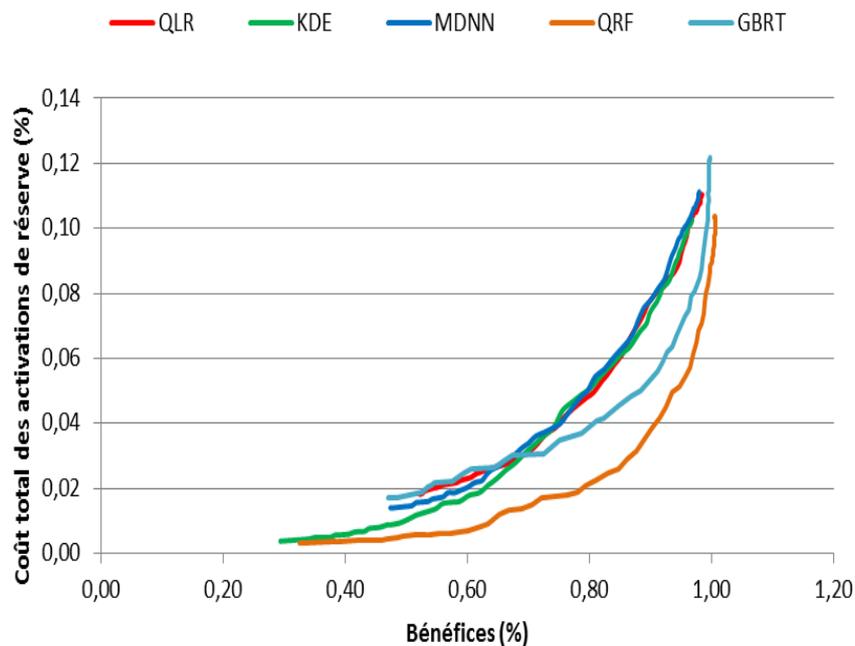
### 5.7.3. Utilisation de modèles de prévision différents

Dans le chapitre 2, nous avons proposé différents modèles de prévision du DLR, générés avec 5 méthodologies différentes :

- Une régression linéaire quantile (QLR)
- Une densité mélange paramétrée par réseaux de neurones (MDNN)
- Un estimateur de densité par noyau (KDE)
- Une régression quantile par forêt aléatoire (QRF)
- Un Gradient Boosting Regression Tree (GBRT)

Nous proposons dans cette section de reprendre les prévisions générées pour une station météorologique avec les 5 méthodologies proposées, et de les tester avec le cas d'étude 2.

Sur la **Figure 5-9**, on représente l'évolution des coûts de réserve, en fonction des bénéfices obtenus grâce au DLR, la fonction de pénalité étant ici la fonction linéaire.



**Figure 5-9.** Evolution des coûts de réserve en fonction des bénéfices observés et de la stratégie de sélection du DLR. La stratégie de sélection de la prévision DLR optimale est une stratégie d'optimisation aversive au risque, la fonction de pénalité  $v_{\beta}$  utilisée étant une fonction linéaire.

On observe des résultats similaires, que ce soit pour l'utilisation de quantiles fixés ou de fonctions de pénalités quadratiques. Comme attendu à la fin du chapitre 2, parmi les 5 modèles présentés, le QRF apparaît comme le plus performant, que ce soit pour des niveaux de bénéfices élevés ( $\approx 1,0\%$ ) ou faibles ( $\approx 0,4\%$ ).

Deux autres modèles sont à mettre en avant, en raison de leurs comportements différents, le KDE et le GBRT. Pour des niveaux de bénéfices élevés, le GBRT apparaît comme étant le plus proche du QRF, mais il échoue à fournir de bonnes performances pour des niveaux de bénéfices faible. Le KDE, lui, a un comportement opposé, fournissant de meilleures performances pour les niveaux de bénéfices faibles.

On résume ces résultats sur le **Tableau 5-5**, en comparant les modèles pour un niveau de bénéfice faible et un niveau de bénéfice fort.

**Tableau 5-5.** A niveaux de bénéfices égaux, comparaison des coûts de réserve générés avec l'utilisation de modèles de prévision différents.

	Coût des activations de réserve avec le GBRT (%)	Coût des activations de réserve avec le KDE (%)	Coût des activations de réserve avec le QRF (%)
Niveaux de bénéfices observé = 0,47%	0,017	0,008	0,004
Niveaux de bénéfices observé = 0,97%	0,079	0,102	0,062

Cela illustre un point attendu qui est que deux modèles de prévision différents peuvent avoir des performances différente d'un point de vue des bénéfices associés à leur utilisation, en fonction de la stratégie d'utilisation du DLR mise en place par les gestionnaires de réseau, et il est alors difficile d'évaluer des modèles de prévision du DLR sans préalablement connaître la stratégie utilisée à terme.

On constate aussi que les niveaux de bénéfices maximums fournis par les modèles de prévision varient peu, allant de réductions des coûts d'opération de 0,97% à 1,01%, soit des évolutions inférieures à 4%.

Par rapport à ces bénéfices maximums, on notera d'ailleurs une corrélation linéaire forte entre les CRPS des modèles et les bénéfices maximum ( $-0,84$ ), même si le nombre de modèles est trop faible pour généraliser cette observation.

Cette corrélation peut encore augmenter, dès que l'on considère que les valeurs des observations et des prévisions DLR en dehors d'un intervalle donné sont ramenées aux bornes de cet intervalle. C'est le même procédé que le traitement fait de certaines prévisions de production de fermes éoliennes qui peuvent être négatives et qui sont ramenées à 0MW, sauf qu'ici on fixe ces valeurs minimales et maximales en accord avec les besoins associés au DLR, ces besoins étant définis par les caractéristiques du réseau électrique.

Par exemple, pour notre cas d'étude, la table de correspondance présentée en 0 montre que des évolutions du DLR au-delà de 130% du SLR n'ont aucun impact sur les coûts d'opération du réseau, la congestion sur la ligne équipée de DLR disparaissant au-delà de cette valeur. Ainsi, dans notre cas, le fait de ramener les valeurs de DLR dans un intervalle  $[SLR, SLR*1,30]$  a pour effet d'améliorer la corrélation entre le CRPS et les bénéfices maximum, qui passe alors de  $-0,84$  à  $-0,94$ .

Pour des niveaux de bénéfices plus faibles, les évolutions en termes de coût de réserve des modèles les uns par rapport aux autres sont importantes. En reprenant le **Tableau 5-5**, on constate qu'entre le GBRT

et le QRF, à niveaux de bénéfices équivalents (0,47%), les coûts de réserve peuvent être divisés par un facteur 4, passant de 0,017% à 0,004%. Relativement à des valeurs de risque ou de bénéfices initiales, et au point actuel de l'état de l'art sur la prévision DLR, ces résultats montrent que les améliorations des modèles de prévision peuvent aisément apporter des bénéfices en terme financiers ou en termes de fiabilité qui sont importants.

Au terme de cette section sur la comparaison des modèles, une perspective apparaissant est le développement d'une approche exploratoire permettant d'analyser la sensibilité des bénéfices d'utilisations de prévisions DLR aux spécificités des modèles de prévision.

A terme, une piste qui nous semblerait intéressante serait la création de fonctions de perte, utilisées dans les entraînements des modèles de prévision, adaptées au problème d'optimisation posé au gestionnaire de réseau. On a ainsi vu ici que l'un des problèmes d'optimisation stochastique proposé ici pouvait considérer les coûts des sous-estimations de prévision DLR comme évoluant de manière linéaire avec la magnitude de l'erreur, et les coûts des surestimations comme évoluant de manière quadratique avec la magnitude de l'erreur. La connaissance de telles caractéristiques pourrait être utilisées pour, à terme, définir et évaluer des modèles de prévision DLR.

#### **5.7.4. Utilisation d'un modèle de prévision avec une partie basse de distribution remodelisée**

Dans le chapitre 3, nous avons proposé des modifications de nos modèles de prévision pour fournir des prévisions à quantiles extrêmes différentes. Ces modifications amélioreraient fortement la fiabilité des modèles de prévision, mais dégradèrent la finesse de ces modèles. Comme dans la section 5.7.3 où nous évaluons des modèles de prévisions différents, nous proposons ici de reprendre les prévisions du chapitre 3 et de les évaluer pareillement.

Comme cette étude se concentre sur les bénéfices associés à des prévisions pour des quantiles de l'ordre de 1%, dans cette partie, nous n'utilisons non plus une seule station météorologique mais les données de six stations concaténées pour avoir un nombre de points plus important. Pour chaque station, des valeurs de SLR différentes sont calculées pour chaque saison comme précédemment, de manière à être inférieures aux valeurs de RTLR 99% du temps. Un total de 43521 points est alors considéré.

Trois modèles de prévisions sont ici repris. D'abord un modèle QRF non modifié (QRF). Ensuite, comme proposé dans le chapitre 3, deux modèles modifiés avec des interpolations exponentielles aux paramètres définis à l'aide de 4 clusters sur les quantiles (5%,10%) (QRF\_EI\_4clusters), et des interpolations exponentielles définies avec 9 clusters basés sur les mêmes couples de quantiles (QRF\_EI\_9clusters).

Pour rappel, l'utilisation de la méthodologie d'utilisation des interpolations exponentielles permettait de générer des modèles ayant une meilleure fiabilité que des modèles de prévision non modifiés, mais cela s'accompagnait d'une dégradation de la finesse et des indices du score quantile pour les quantiles bas. Une question qui s'était posée à la fin du chapitre 3 était alors de savoir si ces modifications apportaient des bénéfices pour l'utilisation des prévisions DLR ou non. Au vu de certains articles où les modèles de prévision DLR ne sont évalués qu'avec le critère de la fiabilité, comme [73] ou [72], la réponse pourrait simplement être positive, mais nous souhaitons ici vérifier la pertinence du choix unique de ce critère de la fiabilité pour évaluer des modèles de prévision du DLR.

### 5.7.4.1. Comparaison des modèles de prévision dans le cadre de l'utilisation de quantiles fixes

Une première comparaison entre les différents modèles de prévision peut être faite en comparant les résultats obtenus avec une utilisation de quantiles à 1%. Les résultats obtenus sont montrés sur le **Tableau 5-6**.

**Tableau 5-6.** Dans le cadre de l'utilisation de quantiles fixés à 1%, comparaison de modèles de prévision différents.

Modèle de prévision utilisé	QRF	QRF_EI_4clusters	QRF_EI_9clusters	Prévisions parfaites
Stratégie utilisée	Utilisation de quantiles fixés à 1%	Utilisation de quantiles fixés à 1%	Utilisation de quantiles fixés à 1%	-
Bénéfices observés (%)	0,61	0,46	0,46	1,10
Coût total des activations de réserve (%)	$16,2 \cdot 10^{-3}$	$10,9 \cdot 10^{-3}$	$10,1 \cdot 10^{-3}$	-
Fréquence de situations nécessitant une activation de réserve (%)	0,76	0,44	0,40	-
Fréquence des situations nécessitant une activation de réserve au coût supérieur à 1000€ (%)	0,29	0,21%	0,18	-
Fréquence des situations nécessitant une activation de réserve au coût supérieur à 1500€ (%)	0,17	0,14	0,13	-

Cette première approche permet de fournir une première comparaison entre des modélisations de partie basses simples à 4 clusters, et plus complexes à 9 clusters, ce en faveur de la deuxième stratégie. Cette deuxième méthodologie permet en effet à niveau de bénéfices égaux de réduire par exemple les coûts de réserve totaux de 10% par rapport à la première.

Il est en revanche difficile de fournir une comparaison similaire permettant d'évaluer l'amélioration apportée par les interpolations exponentielles par rapport au modèle de prévision traditionnel, ces améliorations entraînant des améliorations des coûts de réserve et de la fréquence des erreurs importantes, mais aussi des dégradations des bénéfices.

Ainsi, avec l'apport d'une interpolation exponentielle avec 4 clusters, on est en mesure de réduire les coûts totaux de réserve de 32% par rapport aux coûts associés à l'utilisation du QRF non modifiés, en passant de  $16,2 \cdot 10^{-3}$  % à  $10,9 \cdot 10^{-3}$  % des coûts totaux du système. En revanche, ces réductions s'accompagnent aussi d'une dégradation des bénéfices, ceux-ci étant réduits de 25%, en passant de 0,61% à 0,46%.

Comme précédemment, on regarde alors les courbes liant l'évolution des bénéfices avec les erreurs de coûts totaux et les fréquences des erreurs au coût important (**Figure 5-11**). On regarde aussi les caractéristiques des points de cette courbe qui sont associés à des bénéfices de 0,61%, correspondant à l'utilisation de quantiles fixés à 1% avec le modèle QRF non modifié (**Tableau 5-7**).

**Tableau 5-7.** Comparaison de l'utilisation de modèles de prévision différents, pour un niveau de bénéfice fixé à 0,61%.

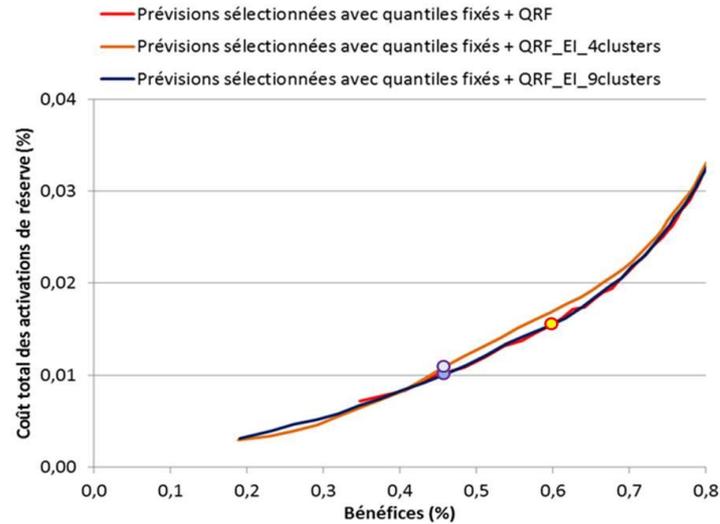
Modèle utilisé	QRF	QRF_EI_4clusters	QRF_EI_9clusters	Prévisions parfaites
Stratégie utilisée	Utilisation de quantiles fixés à 1%	Utilisation de quantiles fixés à 1,6%	Utilisation de quantiles fixés à 1,6%	-
Bénéfices observés (%)	0,61	0,60	0,61	1,10
Coût total des activations de réserve (%)	0,016	0,017	0,016	-
Fréquence de situations nécessitant une activation de réserve (%)	0,76	0,65	0,64	-
Fréquence des situations nécessitant une activation de réserve au coût supérieur à 1000€ (%)	0,29	0,33	0,30	-
Fréquence des situations nécessitant une activation de réserve au coût supérieur à 1500€ (%)	0,17	0,22	0,20	-

Le résultat est contraire à ce qui était attendu : les résultats sont en défaveur des modifications proposées dans le chapitre 3, en dépit des améliorations importantes de la fiabilité.

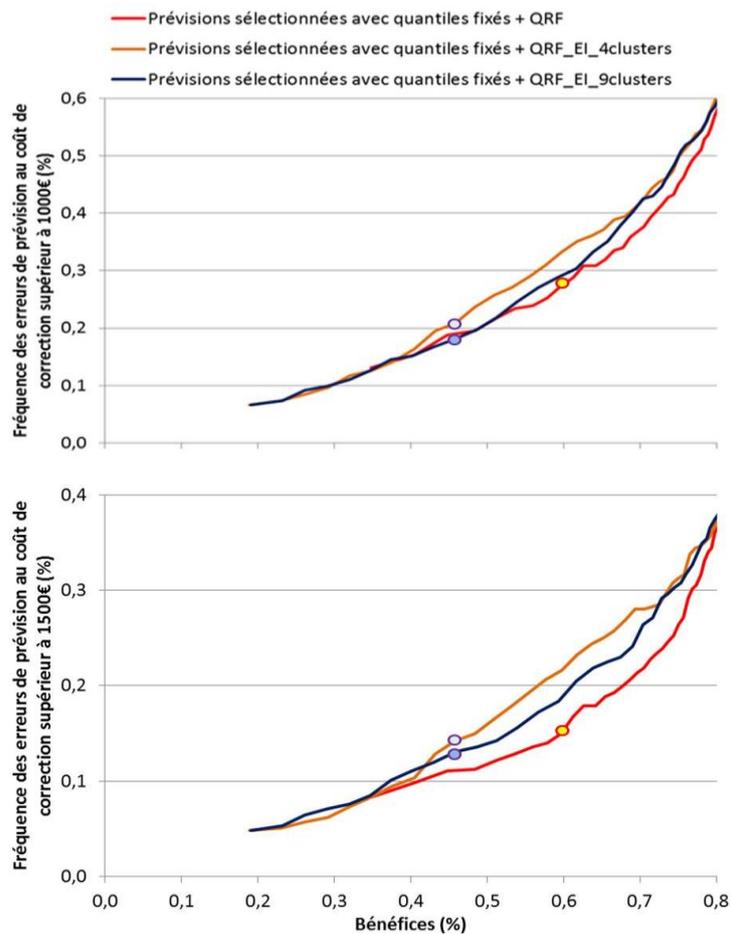
Pour le coût total des erreurs de prévision, seules les interpolations à 9 clusters apparaissent comme permettant de maintenir ces coûts au même niveau que lors de l'utilisation du modèle QRF non modifié. Cependant, une augmentation importante des fréquences des erreurs au coût important. Pour un niveau de bénéfice de 0,61% correspondant à l'utilisation de quantiles 1% avec le QRF, la fréquence de situations entraînant des corrections au coût supérieur à 1500€ passe ainsi de 0,17% à 0,20%. Dans une approche traditionnelle d'utilisation des prévisions DLR, les modifications que nous avons proposées apparaissent comme dégradant nos prévisions.

Dans la partie 5.7.3, où nous avons comparé des modèles de prévision différents, il était difficile de discuter de la pertinence du seul critère de la fiabilité pour évaluer des modèles de prévision, le modèle QRF étant meilleur que les 4 autres à la fois sur la finesse et sur la fiabilité.

Cependant, ici, nous proposons d'utiliser trois modèles de prévision qui permettent de discuter ce point, deux modèles étant bien meilleurs pour le critère de la fiabilité mais étant aussi moins fin. Or, nous montrons que ces modèles entraînent une dégradation importante des performances économiques dès que des quantiles fixés sont utilisés.



**Figure 5-10.** Evolution des coûts de réserve en fonction des bénéfices observés et de la stratégie de sélection du DLR. Les points correspondent à l'utilisation de quantiles fixés à 1%, en jaune avec le modèle QRF non modifié et en bleu avec les modèles modifiés.



**Figure 5-11.** Evolution des fréquences de situations où des activations de réserve au coût supérieur à 1000€ et 1500€ sont nécessaires, en fonction des bénéfices. Les points correspondent à l'utilisation de quantiles fixés à 1%, en jaune avec le modèle QRF non modifié et en bleu avec les modèles modifiés.

### 5.7.4.2. Comparaison des modèles de prévision dans le cadre de l'utilisation de stratégie averse au risque

Nous nous intéressons maintenant à l'apport des modifications proposées dans le chapitre 3, dans le cadre de l'utilisation des stratégies averse au risque que nous proposons.

Pour l'utilisation de pénalités linéaires, les évolutions des coûts de réserve et des fréquences de situations nécessitant des coûts de réserve importants par rapport aux bénéfices sont montrés sur la **Figure 5-12** et la **Figure 5-13**. Le même résultat pour l'utilisation de pénalités quadratique est montré sur la **Figure 5-14** et la **Figure 5-15**. Les mêmes trois modèles de prévision que dans la section 5.7.4.1 sont utilisés.

Pour une lecture plus facile, on évalue aussi les modèles pour des niveaux de bénéfices de 0,61%, comme dans la section 5.7.4 (**Tableau 5-8**). Seuls les modèles modifiés avec des interpolations exponentielles générés avec 9 clusters sont utilisés dans les résultats de ce tableau, ce modèle fournissant des résultats légèrement meilleurs que lorsque 4 clusters seulement sont utilisés.

**Tableau 5-8.** Comparaison de l'utilisation de modèles de prévision différents, pour un niveau de bénéfice fixé à 0,61%.

Modèle utilisé	QRF			QRF+EI_9clusters	
	Utilisation de quantiles fixés à 1%	Pénalités linéaires	Pénalités quadratiques	Pénalités linéaires	Pénalités quadratiques
Bénéfices observés (%)	0,61	0,61	0,61	0,60	0,60
Coût total des activations de réserve (%)	$16,2 \cdot 10^{-3}$	$13,6 \cdot 10^{-3}$	$15,7 \cdot 10^{-3}$	$12,5 \cdot 10^{-3}$	$16,9 \cdot 10^{-3}$
Fréquence de situations nécessitant une activation de réserve (%)	0,76	0,65	0,94	0,51	1,07
Fréquence des situations nécessitant une activation de réserve au coût supérieur à 1000€ (%)	0,29	0,25	0,23	0,24	0,21
Fréquence des situations nécessitant une activation de réserve au coût supérieur à 1500€ (%)	0,17	0,14	0,13	0,15	0,12

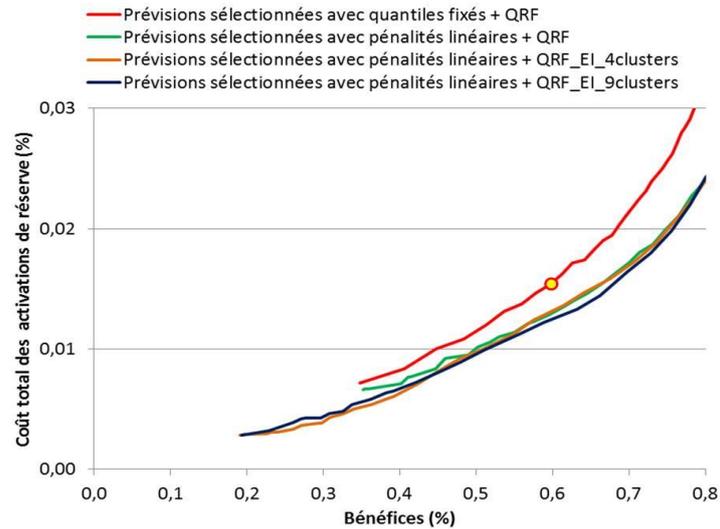
Avec les pénalités linéaires, contrairement à ce qui est montré dans la partie 5.7.4.1, ici, les modifications des modèles de prévisions entraînent des améliorations notables pour les coûts totaux de réserve.

Ainsi, avec un niveau de bénéfice observé de 0,61%, plutôt que de réduire les coûts totaux de 16,0%, passant de  $16,2 \cdot 10^{-3}$  % à  $13,6 \cdot 10^{-3}$  %, les pénalités linéaires permettent maintenant une réduction de ces coûts de 22,8% lorsque l'on utilise les modifications proposées des modèles de prévision, en réduisant les coûts de réserve de  $16,2 \cdot 10^{-3}$  % à  $12,5 \cdot 10^{-3}$  %.

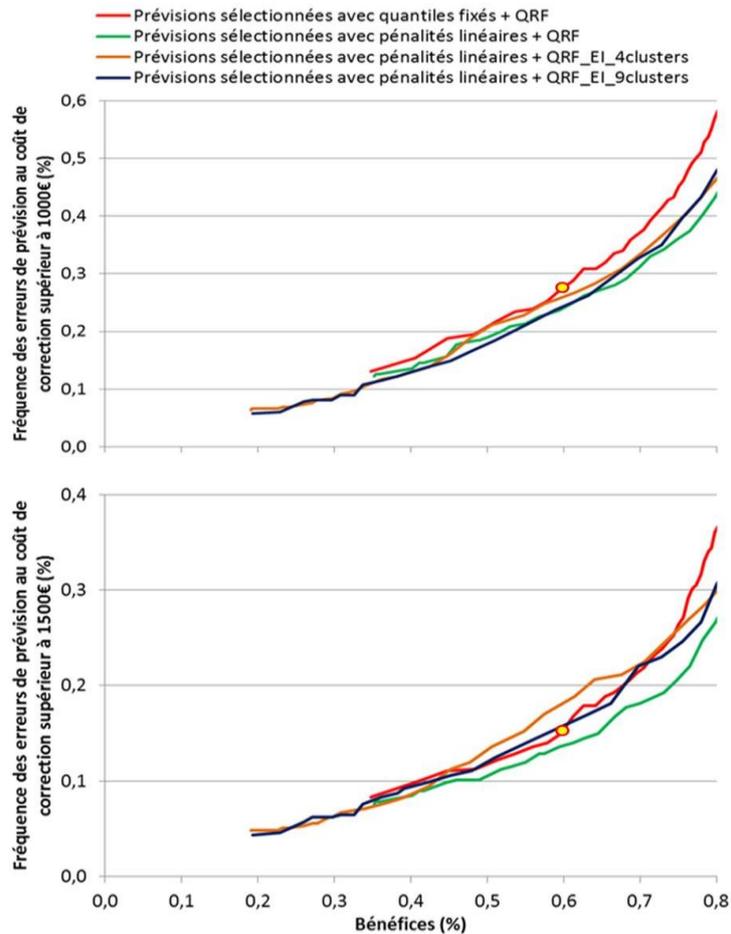
De manière similaire, là où sans modifications des modèles de prévisions et pour un niveau de bénéfice de 0,61%, l'utilisation de pénalités quadratiques permet de réduire la fréquence des erreurs au coût supérieur à 1500 € de 18%, passant de 0,17% à 0,14%, l'ajout des modifications des modèles de prévision permet de monter ce pourcentage d'amélioration à 29%, la nouvelle fréquence étant de 0,12%. Ces améliorations se font cependant au coût d'une dégradation des coûts totaux de réserve, ceux-ci étant augmentés de 4% là où l'utilisation du modèle QRF non modifié n'apportait aucune dégradation.

On avait vu précédemment que les pénalités linéaires étaient utilisées dans une optique de réduire les coûts totaux de réserve, et que les pénalités quadratiques visaient à permettre d'éviter des situations où des erreurs au coût de correction important se produisaient. Ici, les modifications de modèles de prévision permettent d'améliorer les performances associées à l'utilisation de chacune de ces stratégies, parfois au détriment d'indices que l'on ne cherche pas à optimiser avec chacune de ces pénalités.

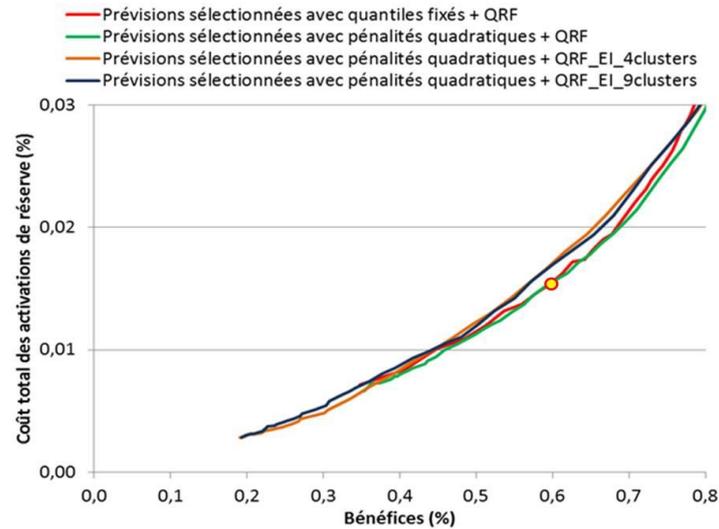
Là où dans le cadre de l'utilisation de quantiles fixes traditionnellement utilisés par des gestionnaires de réseau, les modifications des modèles de prévision du chapitre 3 étaient pénalisantes, ce n'est pas le cas lorsque de nouvelles stratégies dynamiques de sélection des futures prévisions DLR sont utilisées, et les résultats du chapitre 3 seraient alors prometteurs dans le cadre des nouvelles utilisations des prévisions DLR que nous proposons.



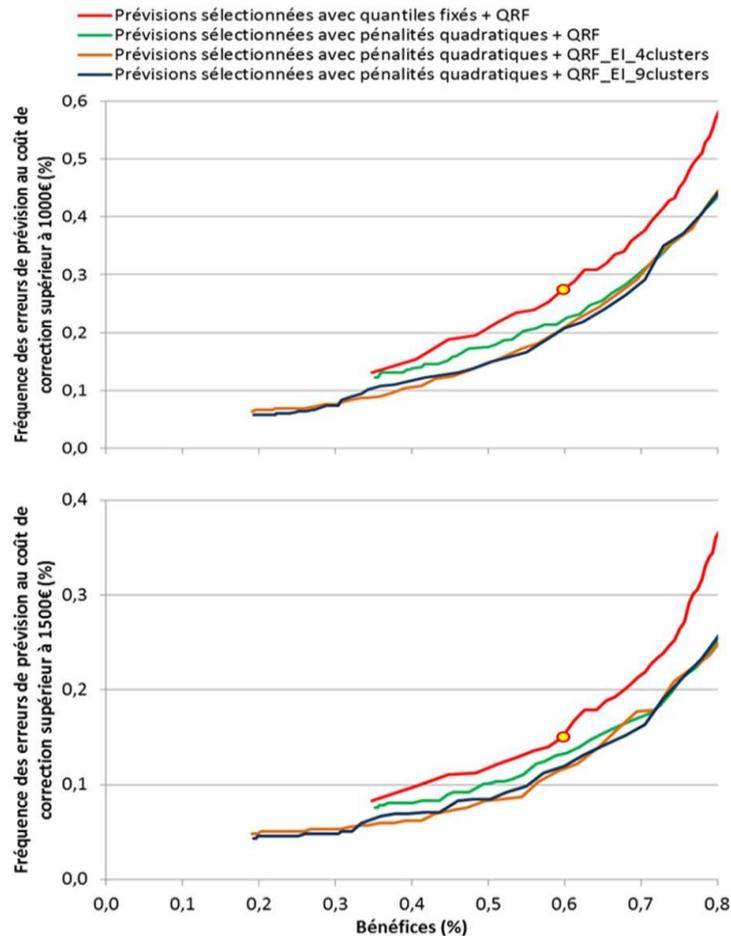
**Figure 5-12.** Evolution des coûts de réserve en fonction des bénéfices observés et de la stratégie de sélection du DLR. Le point jaune correspond à l'utilisation de quantiles fixes à 1% avec le modèle QRF non modifié.



**Figure 5-13.** Evolution des fréquences de situations où des activations de réserve au coût supérieur à 1000€ et 1500€ sont nécessaires, en fonction des bénéfices. Les points jaunes correspondent à l'utilisation de quantiles fixes à 1% avec le modèle QRF non modifié.



**Figure 5-14.** Evolution des coûts de réserve en fonction des bénéfices observés et de la stratégie de sélection du DLR. Le point jaune correspond à l'utilisation de quantiles fixes à 1% avec le modèle QRF non modifié.



**Figure 5-15.** Evolution des fréquences de situations où des activations de réserve au coût supérieur à 1000€ et 1500€ sont nécessaires, en fonction des bénéfices. Les points jaunes correspondent à l'utilisation de quantiles fixes à 1% avec le modèle QRF non modifié.

## 5.8. Conclusions

Les prévisions probabilistes du DLR sont utilisées en pratique au travers de la sélection d'une prévision quantile, avec un niveau de probabilité fixé. Cette méthode limite les bénéfices possibles, et il est aujourd'hui proposé dans la littérature d'utiliser des méthodes d'optimisation pour sélectionner la valeur du DLR future. Il nous semble peu probable que telles méthodes, neutres au risque, puissent être utilisées dans des opérations de dispatch, car là où elles ne visent qu'à maximiser les bénéfices, il est aussi nécessaire de prendre en compte l'aversion du gestionnaire de réseau à accepter des augmentations importantes des coûts à sa charge ou des erreurs de prévision trop importantes.

Nous avons alors proposé dans ce chapitre de modifier le problème d'optimisation proposé dans [60] en ajoutant une composante traduisant l'aversion au risque du gestionnaire de réseau, des pénalités de forme linéaires, quadratiques et exponentielles ayant été considérées.

Les bénéfices ont été significatifs, chacune des deux formes mises en avant étant privilégiée fonction du si le GRT éprouve de l'aversion par rapport aux coûts à sa charge ou au nombre d'erreurs importantes.

Dans un cadre où des gestionnaires de réseau utilisent des scénarios préétablis pour définir par exemple des capacités d'échange en day-ahead, l'idée derrière de telles méthodologies pourrait être réutilisée pour des applications sur le terrain faites par des gestionnaires de réseau utilisant le DLR, et permettraient d'augmenter de manière significative les bénéfices associés à l'utilisation de cette technologie. Pour rappel, par rapport à l'utilisation de quantiles fixés, nous avons montré que nos stratégies pouvaient parfois diviser par deux les coûts de réserve ou le nombre d'erreurs importantes tout en maintenant les bénéfices associés à l'utilisation de prévisions DLR.

Ces méthodologies nous ont permis d'évaluer différents modèles de prévision. Pour des approches neutres au risque, il nous a par exemple été possible d'illustrer une corrélation forte entre les bénéfices économiques et indices d'évaluation des modèles de prévision comme le CRPS.

Pour des niveaux de bénéfices plus faibles, et plus proches des bénéfices associés à des utilisations plus en accord avec les objectifs des gestionnaires de réseau, de telles corrélations n'apparaissent plus. L'indice de la fiabilité, généralement utilisés pour évaluer des prévisions DLR, n'apparaît d'ailleurs pas comme en mesure d'être satisfaisant pour évaluer des bénéfices potentiels associés à des modèles de prévision.

Ainsi, les améliorations les modèles de prévision que nous avons proposés au chapitre 3 et qui apportent de grandes améliorations en termes de fiabilité pour des prévisions à quantile bas, apparaissent comme dégradant la valeur économique des prévisions dans un contexte d'utilisation traditionnelle, le modèle le plus fiable étant même dans notre cas d'étude le pire en termes de performances économiques.

En revanche, ces améliorations ont un impact significatif, dès que des stratégies dynamiques averses au risque sont utilisées. La démonstration de ces points ouvre de nouvelles perspectives sur les caractéristiques requises des modèles de prévision du DLR, les niveaux de probabilité utilisés n'étant alors plus limités à un quantile bas fixé par le gestionnaire de réseau, et les outils proposés ici pourront être utilisés à terme pour, par exemple, définir de nouveaux indices statistiques d'évaluation des prévisions DLR plus adaptés à de nouveaux usages des prévisions DLR.



# CHAPITRE 6

## Conclusions

---

### 6.1. Conclusions générales et contributions

Le DLR est une piste considérée comme une des alternatives les plus prometteuses permettant d'améliorer la gestion d'un réseau aujourd'hui opéré près de ses limites et contraint par des critères d'investissements et de politiques stricts. De nombreux points sont encore à explorer pour utiliser pleinement cette technologie, et dans le cadre de cette thèse, nous nous sommes intéressés à la génération et à l'utilisation de prévisions DLR pour des opérations de planification de production d'électricité.

Nos travaux s'inscrivaient dans un terrain encore relativement vierge : peu de méthodologies associées aux prévisions du DLR à court-terme ont été développées. De plus, les applications étaient encore limitées soit à des utilisations de prévisions à niveau de probabilité fixes, soit à des optimisations stochastiques ne prenant pas compte de certains paramètres comme l'aversion du gestionnaire de réseau à certains critères, comme les coûts à sa charge ou le nombre de situations entraînant des opérations au coût supérieur à un seuil donné.

Dans le cadre de cette thèse, plusieurs contributions ont été proposées. Dans un premier temps, dans le **Chapitre 2**, nous nous sommes intéressés au développement de modèles de prévision à court-terme du DLR. A la suite d'une étude faite sur des prévisions déterministes du DLR dans notre laboratoire qui avaient permis d'identifier des pistes prometteuses pour la génération de prévisions ponctuelles [48], nous nous sommes intéressés au développement d'une étude similaire pour le développement de prévisions probabilistes du DLR. Plusieurs méthodologies ont été testées et évaluées avec des indices d'évaluation traditionnels pour des prévisions probabilistes, soit par la mesure de propriétés données des prévisions comme la fiabilité ou la finesse, soit avec des indices évaluant l'ensemble de ces propriétés comme le CRPS.

Pour la plupart des modèles utilisés, nous avons montré l'existence de phénomènes de surdimensionnement s'exprimant de manière différente en fonction de la partie de la distribution de sortie étudiée. Ainsi, là où un nombre de variables important était nécessaire pour minimiser le CRPS, un indice focalisé sur l'évaluation des quantiles médians, nous avons observé à l'inverse que les phénomènes de surdimensionnement apparaissaient rapidement avec le nombre de variables lorsque les prévisions à quantiles bas et extrêmes étaient considérées.

Pour cette raison, nous avons conclu que, parmi les méthodes que nous avons considérées, les méthodes ensemblistes étaient adaptées à la problématique de la prévision DLR, la régression quantile par forêt

aléatoire et le Gradient Boosting Regression Tree en étant les deux représentants que nous avons choisis dans notre étude. En effet, de tels modèles sont apparus comme peu sensibles aux phénomènes de surdimensionnement, ce qui leur permet de fournir des prévisions à bas quantile de bonne qualité malgré un nombre de variables utilisées important. Ces travaux permettent de démontrer la performance des méthodes ensemblistes pour la prévision du DLR, ce qui n'a pas été fait à l'heure actuelle dans la littérature, et ils fourniront pour des futures recherches des modèles de départ de très bonne qualité.

Nous avons remarqué que ces modèles avaient des difficultés à fournir de manière satisfaisante des prévisions pour des niveaux de probabilité extrêmes, c'est-à-dire inférieurs à 1% dans nos cas d'étude.

Nous avons supposé que de telles prévisions pouvaient avoir à terme une utilité dans le cadre de la mise en place de méthodologies d'utilisation des prévisions DLR avec des optimisations stochastiques averses au risque, et nous avons souhaité améliorer les modèles de prévision pour ces niveaux de probabilité.

Dans le **Chapitre 3**, nous avons proposé deux méthodologies permettant d'aller dans ce sens : une première basée sur la théorie des valeurs extrêmes, et une deuxième basée sur des modélisations de parties basse de distribution faites à partir de paramètres de queues définis pour des clusters.

Cette deuxième méthodologie nous a fourni de relativement bons résultats du point de vue de la fiabilité des modèles, permettant d'améliorer la fiabilité des prévisions à très bas quantile, ici 0,1%, en faisant passer la fréquence observée de 0,70% à 0,18%. Pour des prévisions quantiles à 1%, souvent utilisées dans la littérature, nous étions en mesure d'obtenir une fiabilité parfaite, et au vu des méthodes d'évaluation des prévisions probabilistes DLR régulièrement faites seulement avec des évaluations de la fiabilité, ces améliorations apparaissent comme pleinement satisfaisantes.

Cependant, nous avons fait remarquer que ces améliorations se faisaient au coût d'une dégradation importante de la finesse des modèles, la taille des intervalles à 98% augmentant en moyenne de 20A. Alors, malgré la littérature qui nous poussait à juger ces modifications comme satisfaisantes, il ne nous semblait pas évident de pouvoir conclure à ce moment que les modifications apportées pouvaient apporter une plus-value pour l'utilisation des prévisions DLR. Il était alors nécessaire de développer une étude permettant d'évaluer cette plus-value, afin de démontrer que notre proposition menant à l'amélioration de la fiabilité au coût de la finesse était justifiée.

Cela a alors motivé les premiers travaux présentés dans le **Chapitre 4**, où nous nous sommes interrogés sur l'utilité des prévisions DLR et du cadre dans lequel celles-ci étaient utilisées. Nous avons dans un premier temps travaillé à partir d'un cas d'étude simplifié, considérant une ligne virtuelle entre la France et la Belgique. Cette approche était inspirée du travail déjà fait pour des stratégies d'utilisation de prévisions éoliennes par des producteurs [77], et visait à poser un comportement similaire pour un gestionnaire de réseau cherchant à maximiser le bien-être social.

Ce cas d'étude nous a montré l'existence d'un potentiel associé à des stratégies de prévisions du DLR, et nous a permis d'illustrer que, lorsque des stratégies d'optimisation étaient mises en place, des prévisions DLR permettaient d'améliorer de manière significative le bien-être social, c'est-à-dire de réduire les coûts totaux du système dans un contexte où la demande d'électricité est inélastique au prix.

La suite logique était d'utiliser cette étude pour évaluer les prévisions présentées au **Chapitre 2** et au **Chapitre 3**, mais un certain nombre de simplifications dans notre approche initiale posaient des difficultés :

- L'utilisation de notre stratégie générerait un transfert financier entre différents acteurs, le gestionnaire de réseau devant payer des activations de réserve et voyant les revenus de sa rente de congestion baisser au profit des autres acteurs du réseau. Ce point impliquait alors la mise en place de nouvelles politiques de tarif pour l'utilisation du réseau, ce qui rendait notre approche difficile à implanter.
- De plus, aucune considération n'était faite sur la fréquence des situations où des erreurs de prévisions importantes se produisaient, de telle situation pouvant être considérées comme à éviter par le gestionnaire de réseau.
- Enfin, différentes hypothèses étaient à mettre en doute, comme une relation linéaire parfaite entre la valeur du DLR et de la capacité d'échange aux frontières, ou la considération que les évolutions du DLR n'entraînaient pas de variations de prix sur le réseau.

Pour dépasser ces difficultés, nous avons alors décidé de travailler sur un cas d'étude plus complet dans le **Chapitre 5**, avec l'étude d'un problème d'optimisation stochastique tenant compte des données et des contraintes d'un réseau électrique, ainsi que de prévisions DLR réalistes fournies par nos modèles de prévision.

En raison de notre souhait de travailler sur un grand nombre de prévisions et de stratégies d'utilisation, nous avons posé plusieurs hypothèses et simplifications associées au problème d'optimisation stochastique défini, et nous avons développé une approche à base de tables de correspondance nous permettant d'obtenir des résultats dans une durée très fortement réduite.

Grâce à cette étude, nous avons d'abord pu illustrer les difficultés associées aux stratégies utilisées par les gestionnaires de réseau, qui réduisent les risques mais limitent les bénéfices, et les stratégies neutres au risque présentées dans la littérature qui à l'inverse augmentent les bénéfices mais font exploser les indices de risque. Pour illustrer ces évolutions, sur le **Tableau 6-1** où nous reprenons en exemple les résultats du **Tableau 5-4**, nous montrons par exemple que là où une stratégie d'optimisation neutre au risque permet de presque doubler les bénéfices par rapport aux stratégies traditionnellement utilisées par les gestionnaires de réseau, cela s'accompagne par une multiplication par un facteur 10 des coûts à la charge du gestionnaire de réseau, et d'une multiplication par un facteur 20 du nombre de situations où se produisent des surestimations de DLR futur ayant un coût considéré comme important.

**Tableau 6-1.** Reprise des résultats du **Tableau 5-4** : exemple des mesures de bénéfices et des indices de risque avec les stratégies actuelles des GRT, et les stratégies neutres au risque présentes dans la littérature

	Utilisation de quantiles fixés à 1% (Stratégie traditionnelle)	Utilisation d'une stratégie neutre au risque (Stratégie dynamique présentée dans la littérature)
Bénéfices observés (%)	0,57	1,01
Coût total des activations de réserve (%)	0,010	0,108
Fréquence des situations nécessitant une activation de réserve au coût supérieur à 1000€ (%)	0,10	2,24

Nous avons alors souhaité proposer une nouvelle approche visant à optimiser les bénéfices tout en maintenant les coûts et le nombre d'erreurs importantes dans des limites similaires aux stratégies traditionnelles.

Pour ce faire, nous avons modélisé notre problème d'optimisation en ajoutant des pénalités sur les termes de coût de réserve. De manière générale, en maintenant les bénéfices à un niveau donné, nous avons pu observer avec ces stratégies des réductions allant de 30% à 50% des frais à la charge du GRT et des fréquences d'erreurs importantes.

En plus de ces évaluations de bénéfices associés à de nouvelles stratégies, nos modèles nous offraient l'opportunité de donner une valeur économique à nos modèles de prévision, en fonction de leurs qualités. Ainsi, et même si ce résultat est difficile à généraliser en raison du faible nombre de modèles utilisés, nous pouvions montrer un haut niveau de corrélation entre des bénéfices associés à des prévisions probabilistes DLR utilisés dans une approche neutre au risque et des indices d'évaluation de ces prévisions comme le CRPS.

Pour des approches averses au risque, nous avons cherché à évaluer les modifications proposées dans le chapitre 3 pour les modélisations des parties basses des distributions. Les résultats furent remarquables, en raison d'une évaluation des apports de telles modifications différentes en fonction de la stratégie d'utilisation des modèles de prévision.

Ainsi, avec les stratégies d'utilisation des prévisions traditionnelles, à quantiles fixes, nous avons montré que les modifications des modèles de prévision entraînaient des dégradations importantes. Par exemple, en conservant un niveau de bénéfices associé une approche traditionnelle d'utilisation de quantile fixé à 1%, nous avons montré que nos modifications entraînaient une augmentation de la fréquence des erreurs au coût supérieur à 1000€ de 25%.

A l'inverse, lorsque nos nouvelles approches dynamiques étaient utilisées, des bénéfices étaient cette fois associés aux modifications de nos modèles de prévision, en particulier lorsque ces modifications étaient faites avec des approches complexes, ici une approche basée sur l'utilisation de 9 clusters générés à partir des prévisions quantiles (5%,10%). Cela démontre alors que là où une approche simple était de considérer la seule fiabilité comme le critère déterminant pour l'évaluation d'une prévision DLR, un processus d'évaluation optimal des prévisions DLR est en réalité beaucoup plus complexe à mettre en place, celui-ci dépendant de plusieurs caractéristiques des prévisions DLR mais aussi du cadre d'utilisation de celles-ci.

## 6.2. Perspectives

### 6.2.1. Améliorations possibles de la description du problème d'optimisation stochastique

Dans le dernier chapitre de cette thèse, nous avons proposé un modèle d'optimisation stochastique permettant de prendre en compte les prévisions DLR. Notre modèle repose sur une connaissance parfaite à l'avance des futures valeurs des différents paramètres du réseau. Or, il peut être nécessaire d'ajouter d'autres variables stochastiques, comme par exemple les futures valeurs de production de source d'énergies intermittentes. Une telle approche est proposée dans [148], un article écrit en partie avec des résultats de notre thèse, mais l'approche est neutre au risque et nous avons ici présenté les difficultés pour le GRT à adopter une telle stratégie. Il serait alors intéressant de considérer l'ajout d'autres variables stochastiques, en considérant toujours l'aversion au risque du GRT.

Il serait aussi possible de considérer un changement de nature de l'objectif cherché par le GRT. Ici nous avons développé une méthodologie visant à maximiser le bien-être social qui impose une connaissance sur l'ensemble des valeurs possibles des différentes variables stochastiques. Une autre approche pourrait être une approche visant à imposer par exemple des niveaux de risque associés aux prévisions DLR choisies égaux aux niveaux de risque associé à l'utilisation du SLR. Une telle approche serait similaire au problème que nous avons posé dans le sens où la sélection de la prévision DLR serait dynamique en accord avec la prévision probabiliste, et en raison du fait que le niveau de risque devant être équivalent à celui du SLR, des prévisions à très bas quantile serait aussi nécessaires. De plus, avec une telle approche, il pourrait ne plus être nécessaire d'avoir une information sur l'ensemble des futures variables stochastiques, seules des prévisions sur les futures valeurs du DLR pouvant être requises dans certains cas. Par rapport à l'approche proposée dans cette thèse, une telle approche pourrait alors être potentiellement plus aisée à implanter par les GRT.

### 6.2.2. Pistes d'amélioration des modèles de prévision

Pour améliorer les modèles de prévision que nous avons définis, une piste considérée était l'ajout de nouvelles variables, comme ici des variables issues de la prise en compte d'un ensemble de prévisions météorologiques fournies pour une région donnée.

Ces modifications ne nous ont pas permis d'obtenir des améliorations significatives, mais d'autres approches pourraient être considérées, que ce soit dans le traitement des variables d'entrée, la génération et l'utilisation d'autres variables que celles proposées, ou encore le choix d'un autre méthodologie pour créer le modèle de prévision. Ainsi, on pourrait considérer d'autres types de prévisions météorologiques, comme des prévisions météorologiques ensemblistes.

Une autre piste d'amélioration serait non dans le développement des modèles de prévision, mais dans la recherche des critères d'évaluation statistiques qui sont à utiliser pour évaluer les prévisions du DLR. Un exemple simple a été présenté dans le chapitre 5, où nous avons montré qu'en imposant des bornes aux variations du DLR dans les calculs de l'indice du CRPS, il était possible d'augmenter de manière significative la corrélation entre des indices statistiques d'évaluation et des niveaux de bénéfices économiques pour des optimisations neutres au risque. La définition de tels indices serait à faire en parallèle à la définition du cadre d'utilisation des prévisions du DLR, une caractéristique donnée d'un modèle de prévision du DLR pouvant avoir une utilité variable fonction du type d'utilisation de la prévision, comme nous l'avons montré en évaluant les modifications de partie basses de distribution de nos modèles de prévision dans un cadre d'utilisation traditionnel des prévisions et dans un nouveau cadre d'utilisation dynamique.

En accord de tels indices d'évaluation, des modèles de prévision pourraient aussi être modifiés. Même si nous n'avons pas pu aborder cette possibilité, il faut signaler que c'était la motivation de l'implantation du GBRT dans notre ensemble de modèles proposés, la fonction de perte étant paramétrable et pouvant être à terme modifiée pour prendre en compte la nature du coût des erreurs des prévisions DLR, par exemple linéaire pour des sous-estimations et quadratiques pour des surestimations.

Un autre travail à effectuer serait associé à la prise en compte de l'ensemble des stations météorologiques situées le long d'une ligne équipées avec le DLR, là où la plupart des études tendent à ne considérer qu'une seule station météorologique pour générer les valeurs de DLR. Dans notre travail et comme dans [48], les cas d'étude nous rendaient difficiles des analyses poussées tenant compte de la nécessité de

sélectionner une section critique à la position variable parmi plusieurs stations, en raison du faible nombre de points qui étaient utilisés.

# Liste des publications

---

## Conférences

- R. Dupin, A. Michiorri, « Dynamic Line Rating Forecasting & Evaluation », **EWEA Technology Workshop**, Wind Power Forecasting 2015, Leuven 1-2 October 2015.
- R. Dupin, A. Michiorri, G. Kariniotakis, “Dynamic Line Rating Day-Ahead Forecasts – Cost Benefit Based Selection of the Optimal Quantile”, **CIREN workshop**, 2016, Helsinki.

## Chapitres de livre

- R. Dupin, A. Michiorri, « Dynamic Line Rating Forecasting », in **Renewable Energy Forecasting : From Models to Applications**. chapter. 13, pp. 325-339; Elsevier - Woodhead Publishing, 2017.

## Article de journal

- F. Teng, R. Dupin, A. Michiorri, G. Kariniotakis, Y. Chen, and G. Strbac, ‘Understanding the Benefits of Dynamic Line Rating under Multiple Sources of Uncertainty’, **IEEE Trans. Power Syst.**, 2017. DOI: 10.1109/TPWRS.2017.2786470.
- R. Dupin, A. Michiorri, G. Kariniotakis, « Optimal Dynamic Line Rating Forecasts Selection Based on Ampacity Probabilistic Forecasting and Network Operators’ Risk Aversion ». Submitted for publication at IEEE Transactions on Power Systems, Under review.
- R. Dupin, A. Michiorri, G. Kariniotakis, R. Bessa, L. Cavalcantes « Dynamic Line Rating Forecasts – Advanced Modelling of Extreme Quantiles and Impact on Forecast Value ». In preparation, target: IEEE Transactions on power systems.
- R. Dupin, A. Michiorri, G. Kariniotakis, « Overhead lines Dynamic Line Rating based on Probabilistic Day-Ahead Forecasting and Risk Assessment ». Submitted for publication at the International Journal of Electrical Power and Energy Systems, Under review.



# Bibliographie

---

- [1] “ENTSO-E at a Glance.” [Online]. Available: <https://www.entsoe.eu/publications/general-publications/entso-e-at-a-glance/Pages/default.aspx>. [Accessed: 12-Mar-2018].
- [2] CRE, “Les interconnexions électriques et gazières en France - Un outil au service de la construction d’un marché européen intégré,” 2016.
- [3] “Map.” [Online]. Available: <https://www.entsoe.eu/map/Pages/default.aspx>. [Accessed: 02-Mar-2018].
- [4] C. C. de régulation de l’énergie, “Qualité de l’électricité - Réseaux publics d’électricité - Réseaux,” *CRE*. [Online]. Available: <http://www.cre.fr/reseaux/reseaux-publics-d-electricite/qualite-de-l-electricite>. [Accessed: 15-Nov-2017].
- [5] P. Bornard, M. Pavard, and G. Testud, “Réseaux d’interconnexion et de transport: réglages et stabilité,” *Tech. Ing. Génie Électr.*, vol. 8, no. D4092, 2005.
- [6] “Approvisionnement électrique: l’Europe sous tension (rapport).” [Online]. Available: <https://www.senat.fr/rap/r06-357-1/r06-357-144.html>. [Accessed: 15-Nov-2017].
- [7] A. CHANAL, “Lignes aériennes: Présentation et calcul des lignes,” *Tech. Ing. Génie Électr.*, vol. 8, no. D4420, p. D4420. 1-D4420. 12, 2000.
- [8] “Wind in power: 2016 European statistics,” *WindEurope*, 09-Feb-2017. [Online]. Available: <https://windeurope.org/about-wind/statistics/european/wind-in-power-2016/>. [Accessed: 14-Dec-2017].
- [9] “EUR-Lex - 32009L0028 - EN - EUR-Lex.” [Online]. Available: <http://eur-lex.europa.eu/legal-content/EN/ALL/?uri=CELEX%3A32009L0028>. [Accessed: 14-Dec-2017].
- [10] “2030 Energy Strategy - Energy - European Commission,” *Energy*. [Online]. Available: </energy/en/topics/energy-strategy-and-energy-union/2030-energy-strategy>. [Accessed: 14-Dec-2017].
- [11] A. Minaud, C. Gaudin, and L. Karsenti, “Analysis of the options to reduce the integration costs of renewable generation in the distribution networks. Part 1: Impact of PV development in France and global analysis of considered alternatives to reinforcement,” in *22nd International Conference and Exhibition on Electricity Distribution (CIRED 2013)*, 2013, pp. 1–4.
- [12] CRE, “Echanges d’électricité aux frontières : utilisation et gestion des interconnexions en 2012,” 2013.
- [13] “La nouvelle ligne à THT France-Espagne, une première mondiale à venir,” *Actu-Environnement*. [Online]. Available: <https://www.actu-environnement.com/ae/news/ligne-tht-france-espagne-tunnel-16889.php4>. [Accessed: 24-Oct-2017].

- [14] N. Hadjsaid, M. C. Alvarez-Hérault, R. Caire, B. Raison, J. Descloux, and W. Bienia, "Novel architectures and operation modes of distribution network to increase DG integration," in *IEEE PES General Meeting*, 2010, pp. 1–6.
- [15] L. F. Ochoa and D. H. Wilson, "Angle constraint active management of distribution networks with wind power," in *2010 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT Europe)*, 2010, pp. 1–5.
- [16] H. P. S. Clair, "Practical Concepts in Capability and Performance of Transmission Lines [includes discussion]," *Trans. Am. Inst. Electr. Eng. Part III Power Appar. Syst.*, vol. 72, no. 2, Jan. 1953.
- [17] P. Bornard, M. Pavard, and G. Testud, *Réseaux d'interconnexion et de transport: fonctionnement*. Ed. Techniques Ingénieur, 2005.
- [18] "Performance Equations and Parameters of Transmission Lines - ppt video online download." [Online]. Available: <http://slideplayer.com/slide/6867975/>. [Accessed: 22-Nov-2017].
- [19] L. Dawson and A. Knight, "Applicability of Dynamic Thermal Line Rating for Long Lines," *IEEE Trans. Power Deliv.*, vol. PP, no. 99, pp. 1–1, 2017.
- [20] H. J. Li, K. C. Tan, and Q. Su, "Assessment of underground cable ratings based on distributed temperature sensing," *IEEE Trans. Power Deliv.*, vol. 21, no. 4, pp. 1763–1769, Oct. 2006.
- [21] T. O. Seppa, "Guide for selection of weather parameters for bare overhead conductor ratings," *CIGRE WG B*, vol. 2, 2006.
- [22] M. Monseu, "Determination of thermal line ratings from a probabilistic approach," in *1991 Third International Conference on Probabilistic Methods Applied to Electric Power Systems*, 1991, pp. 180–184.
- [23] I. Albizu, E. Fernandez, A. J. Mazon, and R. Alberdi, "Forecast ratio and security analysis of rating forecasting methods in an overhead line," *IET Gener. Transm. Distrib.*, vol. 11, no. 6, pp. 1598–1604, 2017.
- [24] J. Fu, D. J. Morrow, S. Abdelkader, and B. Fox, "Impact of Dynamic Line Rating on Power Systems," in *Universities' Power Engineering Conference (UPEC), Proceedings of 2011 46th International*, 2011, pp. 1–5.
- [25] "IEEE Standard for Calculating the Current-Temperature Relationship of Bare Overhead Conductors," *IEEE Std 738-2012 Revis. IEEE Std 738-2006 - Inc. IEEE Std 738-2012 Cor 1-2013*, pp. 1–72, Dec. 2013.
- [26] W. CIGRE, *12, Thermal Behaviour of Overhead Conductors, Tech. Brochure*, 2002.
- [27] J. Fu, D. J. Morrow, S. Abdelkader, and B. Fox, "Impact of dynamic line rating on power systems," in *Universities' Power Engineering Conference (UPEC), Proceedings of 2011 46th International*, 2011, pp. 1–5.
- [28] M. W. Davis, "A new thermal rating approach: The real time thermal rating system for strategic overhead conductor transmission lines – Part I: General description and justification of the real time thermal rating system," *IEEE Trans. Power Appar. Syst.*, vol. 96, no. 3, pp. 803–809, May 1977.
- [29] "Technologies for Transmission System." [Online]. Available: <http://tyndp.entsoe.eu/2016/insight-reports/technology/>. [Accessed: 12-Mar-2018].
- [30] "Dynamic Line Rating for overhead lines – V6." ENTSOE-E, 2015.
- [31] "Pike Electric." [Online]. Available: <http://www.pike.com/EnergySolutions/ThermalRate/Default.aspx>. [Accessed: 24-Oct-2017].
- [32] "POWER DONUT® LINE MONITOR - USi." [Online]. Available: <http://www.usi-power.com/power-donut-line-monitor/>. [Accessed: 24-Oct-2017].

- [33] T. O. Seppa *et al.*, “Use of on-line tension monitoring for real-time thermal ratings, ice loads and other environmental effects,” in *CIGRÉ Session*, 1998, pp. 22–102.
- [34] B. Forbes, D. Bradshaw, and F. Campbell, “Finding ‘hidden capacity’ in transmission lines,” *Transm. Distrib. World*, vol. 54, no. 9, pp. 30–30, 2002.
- [35] J.-L. Lilien, S. Guerard, B. Godard, J. Destiné, and E. Cloet, “Microsystem array for live high voltage lines monitoring,” 2006.
- [36] E. Cloet, J.-L. Lilien, and P. Ferrières, “Experiences of the Belgian and French TSOs using the ‘Ampacimon’ real-time dynamic rating system,” in *Conférence Internationale des grands réseaux électriques à haute tension*, 2010.
- [37] A. Michiorri, R. Currie, P. Taylor, F. Watson, and D. Macleman, “Dynamic line ratings deployment on the orkney smart grid,” in *CIGRE*, 2011.
- [38] E. Fernandez, I. Albizu, M. T. Bedialauneta, A. J. Mazon, and P. T. Leite, “Review of dynamic line rating systems for wind power integration,” *Renew. Sustain. Energy Rev.*, vol. 53, pp. 80–92, 2016.
- [39] N. P. Schmidt, “Comparison between IEEE and CIGRE ampacity standards,” *IEEE Trans. Power Deliv.*, vol. 14, no. 4, pp. 1555–1559, 1999.
- [40] P. Pytlak, P. Musilek, and E. Lozowski, “Precipitation-based conductor cooling model for dynamic thermal rating systems,” in *Electrical Power & Energy Conference (EPEC), 2009 IEEE*, 2009, pp. 1–7.
- [41] P. Pytlak, P. Musilek, E. Lozowski, and J. Toth, “Modelling precipitation cooling of overhead conductors,” *Electr. Power Syst. Res.*, vol. 81, no. 12, pp. 2147–2154, 2011.
- [42] C. Gary, *Effet couronne sur les réseaux électriques aériens*. Ed. Techniques Ingénieur, 1998.
- [43] T. L. Le, M. Negnevitsky, and M. Piekutowski, “Expert system application for the loading capability assessment of transmission lines,” *IEEE Trans. Power Syst.*, vol. 10, no. 4, pp. 1805–1812, Nov. 1995.
- [44] M. Matus *et al.*, “Identification of Critical Spans for Monitoring Systems in Dynamic Thermal Rating,” *IEEE Trans. Power Deliv.*, vol. 27, no. 2, pp. 1002–1009, Apr. 2012.
- [45] S. Uski, “Estimation method for dynamic line rating potential and economic benefits,” *Int. J. Electr. Power Energy Syst.*, vol. 65, pp. 76–82, Feb. 2015.
- [46] S. Uski, “Dynamic line rating forecastability for conservative day-ahead line rating values,” in *IECON 2015 - 41st Annual Conference of the IEEE Industrial Electronics Society*, 2015, pp. 003738–003742.
- [47] W. J. Steeley, B. L. Norris, and A. K. Deb, “Ambient temperature corrected dynamic transmission line ratings at two PG amp;E locations,” *IEEE Trans. Power Deliv.*, vol. 6, no. 3, pp. 1234–1242, Jul. 1991.
- [48] J. L. Aznarte and N. Siebert, “Dynamic Line Rating Using Numerical Weather Predictions and Machine Learning: A Case Study,” *IEEE Trans. Power Deliv.*, vol. 32, no. 1, pp. 335–343, Feb. 2017.
- [49] B. C. Lesieutre and J. H. Eto, “Electricity transmission congestion costs: A review of recent reports,” *Lawrence Berkeley Natl. Lab.*, 2003.
- [50] M. Khaki, P. Musilek, J. Heckenbergerova, and D. Koval, “Electric power system cost/loss optimization using dynamic thermal rating and linear programming,” in *Electric Power and Energy Conference (EPEC), 2010 IEEE*, 2010, pp. 1–6.
- [51] M. A. Bucher, M. Vrakopoulou, and G. Andersson, “Probabilistic N-1 security assessment incorporating dynamic line ratings,” in *2013 IEEE Power Energy Society General Meeting*, 2013, pp. 1–5.

- [52] K. E. Holbert and G. T. Heydt, "Prospects for dynamic transmission circuit ratings," in *ISCAS 2001. The 2001 IEEE International Symposium on Circuits and Systems (Cat. No.01CH37196)*, 2001, vol. 3, pp. 205–208 vol. 2.
- [53] M. Miura, T. Satoh, S. Iwamoto, and I. Kurihara, "Application of dynamic rating to evaluation of ATC with thermal constraints considering weather conditions," in *2006 IEEE Power Engineering Society General Meeting*, 2006, pp. 6 pp.-.
- [54] A. K. Kazerooni, J. Mutale, M. Perry, S. Venkatesan, and D. Morrice, "Dynamic thermal rating application to facilitate wind energy integration," in *PowerTech, 2011 IEEE Trondheim*, 2011, pp. 1–7.
- [55] T. Ringelband, M. Lange, M. Dietrich, and H.-J. Haubrich, "Potential of improved wind integration by dynamic thermal rating of overhead lines," in *PowerTech, 2009 IEEE Bucharest*, 2009, pp. 1–5.
- [56] H. T. Yip, C. An, M. Aten, and R. Ferris, "Dynamic line rating protection for wind farm connections," 2008.
- [57] R. Moreno, D. Pudjianto, and G. Strbac, "Integrated reliability and cost–benefit-based standards for transmission network operation," *Proc. Inst. Mech. Eng. Part O J. Risk Reliab.*, vol. 226, no. 1, pp. 75–87, 2012.
- [58] C. J. Wallnerström, Y. Huang, and L. Söder, "Impact From Dynamic Line Rating on Wind Power Integration," *IEEE Trans. Smart Grid*, vol. 6, no. 1, pp. 343–350, Jan. 2015.
- [59] S. Mohtashami, D. Pudjianto, and G. Strbac, "Strategic distribution network planning with smart grid technologies," *IEEE Trans. Smart Grid*, 2016.
- [60] Y. Chen, F. Teng, R. Moreno, and G. Strbac, "Impact of dynamic line rating with forecast error on the scheduling of reserve service," in *Power and Energy Society General Meeting (PESGM), 2016*, 2016, pp. 1–5.
- [61] B. Banerjee, D. Jayaweera, and S. M. Islam, "Optimal scheduling with dynamic line ratings and intermittent wind power," in *PES General Meeting/ Conference & Exposition, 2014 IEEE*, 2014, pp. 1–5.
- [62] B. Banerjee, S. M. Islam, and D. Jayaweera, "Monte Carlo based method for managing risk of scheduling decisions with dynamic line ratings," in *Power & Energy Society General Meeting, 2015 IEEE*, 2015, pp. 1–5.
- [63] B. Banerjee, D. Jayaweera, and S. M. Islam, "Alleviating post-contingency congestion risk of wind integrated systems with dynamic line ratings," in *Power Engineering Conference (AUPEC), 2014 Australasian Universities*, 2014, pp. 1–6.
- [64] D. M. Greenwood and P. C. Taylor, "Investigating the Impact of Real-Time Thermal Ratings on Power Network Reliability," *IEEE Trans. Power Syst.*, vol. 29, no. 5, pp. 2460–2468, Sep. 2014.
- [65] K. Kopsidas and A. Kapetanaki, "Optimal demand response scheduling with real time thermal ratings of overhead lines for improved network reliability," *IEEE Trans. Smart Grid*, 2016.
- [66] H. Banakar, N. Alguacil, and F. D. Galiana, "Electrothermal coordination part I: theory and implementation schemes," *IEEE Trans. Power Syst.*, vol. 20, no. 2, pp. 798–805, May 2005.
- [67] N. Alguacil, M. H. Banakar, and F. D. Galiana, "Electrothermal coordination part II: case studies," *IEEE Trans. Power Syst.*, vol. 20, no. 4, pp. 1738–1745, Nov. 2005.
- [68] S. D. Foss and R. A. Maraio, "Dynamic line rating in the operating environment," *IEEE Trans. Power Deliv.*, vol. 5, no. 2, pp. 1095–1105, Apr. 1990.
- [69] A. Michiorri *et al.*, "Forecasting for dynamic line rating," *Renew. Sustain. Energy Rev.*, vol. 52, pp. 1713–1730, Dec. 2015.

- [70] H.-M. Nguyen, J.-J. Lambin, F. Vassort, and J.-L. Lilien, "Operational experience with Dynamic Line Rating forecast-based solutions to increase usable network transfer capacity," *Proc. 45th Sess. Counc. Large Electr. Syst. CIGRE*, 2014.
- [71] H.-M. Nguyen, J.-L. Lilien, and P. Schell, "Dynamic line rating and ampacity forecasting as the keys to optimise power line assets with the integration of res. The European project Twenties Demonstration inside Central Western Europe," 2013.
- [72] X. Sun, P. B. Luh, K. W. Cheung, and W. Guan, "Probabilistic forecasting of dynamic line rating for over-head transmission lines," in *2015 IEEE Power Energy Society General Meeting*, 2015, pp. 1–5.
- [73] T. Ringelband, P. Schäfer, and A. Moser, "Probabilistic ampacity forecasting for overhead lines using weather forecast ensembles.," *Electr. Eng.*, vol. 95, no. 2, 2013.
- [74] S. Malkin and E. Hsieh, "Beyond Real Time: the Computational Challenges of Forecasting Dynamic Line Ratings," presented at the FERC Software Tech Conference, 26-Jun-2013.
- [75] J. F. Hall and A. K. Deb, "Prediction of overhead transmission line ampacity by stochastic and deterministic models," *IEEE Trans. Power Deliv.*, vol. 3, no. 2, pp. 789–800, Apr. 1988.
- [76] H. E. Hoekstra, C. P. J. Jansen, J. Hagen, J. W. Van Schuylenburg, J. S. P. Wisse, and W. J. Zittersteijn, "Weather forecasted thermal line rating model for the Netherlands," in *CIGRE Session*, 2012.
- [77] P. Pinson, C. Chevallier, and G. N. Kariniotakis, "Trading Wind Generation From Short-Term Probabilistic Forecasts of Wind Power," *IEEE Trans. Power Syst.*, vol. 22, no. 3, pp. 1148–1156, Aug. 2007.
- [78] D. J. Aigner, T. Amemiya, and D. J. Poirier, "On the estimation of production frontiers: maximum likelihood estimation of the parameters of a discontinuous density function," *Int. Econ. Rev.*, pp. 377–396, 1976.
- [79] S. K. Schnabel and P. H. Eilers, "Optimal expectile smoothing," *Comput. Stat. Data Anal.*, vol. 53, no. 12, pp. 4168–4177, 2009.
- [80] F. Fan, K. Bell, and D. Infield, "Probabilistic weather forecasting for dynamic line rating studies," in *2016 Power Systems Computation Conference (PSCC)*, 2016, pp. 1–7.
- [81] F. Fan, K. Bell, and D. Infield, "Probabilistic Real-Time Thermal Rating Forecasting for Overhead Lines by Conditionally Heteroscedastic Auto-Regressive Models," *IEEE Trans. Power Deliv.*, vol. 32, no. 4, pp. 1881–1890, Aug. 2017.
- [82] M. Negnevitsky and T. L. Le, "Artificial neural networks application for current rating of overhead lines," in *IEEE International Conference on Neural Networks, 1995. Proceedings*, 1995, vol. 1, pp. 418–422 vol.1.
- [83] Z. Wei, M. Wang, X. Han, H. Zhang, and Q. Zhang, "Probabilistic forecasting for the ampacity of overhead transmission lines using quantile regression method," in *2016 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC)*, 2016, pp. 1632–1635.
- [84] R. Koenker, *Quantile regression*. Cambridge university press, 2005.
- [85] A. Michiorri, P. C. Taylor, and S. C. E. Jupe, "Overhead line real-time rating estimation algorithm: description and validation," *Proc. Inst. Mech. Eng. Part J. Power Energy*, vol. 224, no. 3, pp. 293–304, 2010.
- [86] J. Zhang, J. Pu, J. D. McCalley, H. Stern, and W. A. Gallus, "A Bayesian approach for short-term transmission line thermal overload risk assessment," *IEEE Trans. Power Deliv.*, vol. 17, no. 3, pp. 770–778, Jul. 2002.

- [87] K. Wang, G. Sheng, and X. Jiang, "Risk assessment of transmission dynamic line rating based on Monte Carlo," in *2011 IEEE Power Engineering and Automation Conference*, 2011, vol. 2, pp. 398–402.
- [88] D. M. Kim, J. M. Cho, H. S. Lee, H. S. Jung, and J. O. Kim, "Prediction of Dynamic Line Rating Based on Assessment Risk by Time Series Weather Model," in *2006 International Conference on Probabilistic Methods Applied to Power Systems*, 2006, pp. 1–7.
- [89] A. Michiorri and P. C. Taylor, "Forecasting real-time ratings for electricity distribution networks using weather forecast data," in *CIREN 2009 - 20th International Conference and Exhibition on Electricity Distribution - Part 1*, 2009, pp. 1–4.
- [90] J. Fu, D. J. Morrow, and S. M. Abdelkader, "Modelling and prediction techniques for dynamic overhead line rating," in *Power and Energy Society General Meeting, 2012 IEEE*, 2012, pp. 1–7.
- [91] P. Geladi and B. R. Kowalski, "Partial least-squares regression: a tutorial," *Anal. Chim. Acta*, vol. 185, pp. 1–17, 1986.
- [92] J. A. Nelder and R. J. Baker, *Generalized linear models*. Wiley Online Library, 1972.
- [93] J. H. Friedman, "Multivariate adaptive regression splines," *Ann. Stat.*, pp. 1–67, 1991.
- [94] L. Breiman, "Random forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2001.
- [95] N. Meinshausen, "Quantile regression forests," *J. Mach. Learn. Res.*, vol. 7, no. Jun, pp. 983–999, 2006.
- [96] M. A. Bucher and G. Andersson, "Robust Corrective Control Measures in Power Systems With Dynamic Line Rating," *IEEE Trans. Power Syst.*, vol. 31, no. 3, pp. 2034–2043, May 2016.
- [97] J. Black, S. Connor, and J. Colandairaj, "Planning network reinforcements with dynamic line ratings for overhead transmission lines," in *Universities Power Engineering Conference (UPEC), 2010 45th International*, 2010, pp. 1–6.
- [98] J. Black, J. Colandairaj, S. Connor, and B. O'Sullivan, "Equipment and methodology for the planning and implementation of dynamic line ratings on overhead transmission circuits," in *Modern Electric Power Systems (MEPS), 2010 Proceedings of the International Symposium*, 2010, pp. 1–6.
- [99] L. McClean, L. Bryans, J. Colandairaj, B. Fox, and B. O'Sullivan, "Equipment and methodology for linking overhead line circuit ratings to the output of nearby windfarms," in *Universities Power Engineering Conference, 2008. UPEC 2008. 43rd International*, 2008, pp. 1–5.
- [100] J. Cunningham and J. Colandairaj, "Methodology for applying real-time ratings to wood pole supported overhead lines," in *Universities Power Engineering Conference (UPEC), 2009 Proceedings of the 44th International*, 2009, pp. 1–5.
- [101] R. Koenker and G. Bassett Jr, "Regression quantiles," *Econom. J. Econom. Soc.*, pp. 33–50, 1978.
- [102] J. Carreau and Y. Bengio, "A Hybrid Pareto Mixture for Conditional Asymmetric Fat-Tailed Distributions," *IEEE Trans. Neural Netw.*, vol. 20, no. 7, pp. 1087–1101, Jul. 2009.
- [103] J. Jeon and J. W. Taylor, "Using conditional kernel density estimation for wind power density forecasting," *J. Am. Stat. Assoc.*, vol. 107, no. 497, pp. 66–79, 2012.
- [104] J. Juban, N. Siebert, and G. N. Kariniotakis, "Probabilistic short-term wind power forecasting for the optimal management of wind generation," in *Power Tech, 2007 IEEE Lausanne*, 2007, pp. 683–688.
- [105] R. J. Bessa, V. Miranda, A. Botterud, J. Wang, and E. M. Constantinescu, "Time adaptive conditional kernel density estimation for wind power forecasting," *IEEE Trans. Sustain. Energy*, vol. 3, no. 4, pp. 660–669, 2012.

- [106] Y. Zhang and J. Wang, "GEFCom2014 probabilistic solar power forecasting based on k-nearest neighbor and kernel density estimator," in *2015 IEEE Power Energy Society General Meeting*, 2015, pp. 1–5.
- [107] S. Arora and J. W. Taylor, "Forecasting electricity smart meter data using conditional kernel density estimation," *Omega*, vol. 59, pp. 47–59, 2016.
- [108] D. W. Scott, *Multivariate density estimation: theory, practice, and visualization*. John Wiley & Sons, 2015.
- [109] J. H. Friedman, "Greedy function approximation: a gradient boosting machine," *Ann. Stat.*, pp. 1189–1232, 2001.
- [110] G. Ridgeway, "Generalized Boosted Models: A guide to the gbm package," *Update*, vol. 1, no. 1, p. 2007, 2007.
- [111] J. Snoek, H. Larochelle, and R. P. Adams, "Practical bayesian optimization of machine learning algorithms," in *Advances in neural information processing systems*, 2012, pp. 2951–2959.
- [112] P. Pinson, H. A. Nielsen, J. K. Møller, H. Madsen, and G. N. Kariniotakis, "Non-parametric probabilistic forecasts of wind power: required properties and evaluation," *Wind Energy*, vol. 10, no. 6, pp. 497–516, 2007.
- [113] Z. Toth, O. Talagrand, G. Candille, and Y. Zhu, *Probability and ensemble forecasts*. Wiley, 2003.
- [114] I. J. Good, "Rational Decisions," *1952*, pp. 107–114, 1952.
- [115] T. Hong, P. Pinson, S. Fan, H. Zareipour, A. Troccoli, and R. J. Hyndman, *Probabilistic energy forecasting: Global energy forecasting competition 2014 and beyond*. Elsevier, 2016.
- [116] J. E. Matheson and R. L. Winkler, "Scoring rules for continuous probability distributions," *Manag. Sci.*, vol. 22, no. 10, pp. 1087–1096, 1976.
- [117] T. Gneiting, A. E. Raftery, A. H. Westveld III, and T. Goldman, "Calibrated probabilistic forecasting using ensemble model output statistics and minimum CRPS estimation," *Mon. Weather Rev.*, vol. 133, no. 5, pp. 1098–1118, 2005.
- [118] G. W. Brier, "Verification of forecasts expressed in terms of probability," *Mon. Weather Rev.*, vol. 78, no. 1, pp. 1–3, 1950.
- [119] T. Gneiting and A. E. Raftery, "Strictly proper scoring rules, prediction, and estimation," *J. Am. Stat. Assoc.*, vol. 102, no. 477, pp. 359–378, 2007.
- [120] J. R. Andrade and R. J. Bessa, "Improving renewable energy forecasting with a grid of numerical weather predictions," *IEEE Trans. Sustain. Energy*, 2017.
- [121] T. H. Cormen, C. E. Leiserson, R. L. Rivest, and C. Stein, "Greedy algorithms," *Introd. Algorithms*, vol. 1, pp. 329–355, 2001.
- [122] S. Wold, K. Esbensen, and P. Geladi, "Principal component analysis," *Chemom. Intell. Lab. Syst.*, vol. 2, no. 1–3, pp. 37–52, 1987.
- [123] J. Carreau and M. Vrac, "Stochastic downscaling of precipitation with neural network conditional mixture models," *Water Resour. Res.*, vol. 47, no. 10, 2011.
- [124] M. A. Matos and R. J. Bessa, "Setting the operating reserve using probabilistic wind power forecasts," *IEEE Trans. Power Syst.*, vol. 26, no. 2, pp. 594–603, 2011.
- [125] J. Beirlant, T. D. Wet, and Y. Goegebeur, "Nonparametric estimation of extreme conditional quantiles," *J. Stat. Comput. Simul.*, vol. 74, no. 8, pp. 567–580, 2004.
- [126] G. Matthys and J. Beirlant, "Estimating the extreme value index and high quantiles with exponential regression models," *Stat. Sin.*, pp. 853–880, 2003.

- [127] L. De Haan and A. Ferreira, *Extreme value theory: an introduction*. Springer Science & Business Media, 2007.
- [128] J. Pickands III, “Statistical inference using extreme order statistics,” *Ann. Stat.*, pp. 119–131, 1975.
- [129] M. A. Matos *et al.*, “Setting the maximum import net transfer capacity under extreme RES integration scenarios,” in *2016 International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*, 2016, pp. 1–7.
- [130] T. Jónsson, P. Pinson, H. Madsen, and H. A. Nielsen, “Predictive densities for day-ahead electricity prices using time-adaptive quantile regression,” *Energies*, vol. 7, no. 9, pp. 5523–5547, 2014.
- [131] F. Pedregosa *et al.*, “Scikit-learn: Machine learning in Python,” *J. Mach. Learn. Res.*, vol. 12, no. Oct, pp. 2825–2830, 2011.
- [132] S. Lloyd, “Least squares quantization in PCM,” *IEEE Trans. Inf. Theory*, vol. 28, no. 2, pp. 129–137, 1982.
- [133] W. Li, P. Wang, and Z. Guo, “Determination of optimal total transfer capability using a probabilistic approach,” *IEEE Trans. Power Syst.*, vol. 21, no. 2, pp. 862–868, May 2006.
- [134] Elia, “Modèle général de calcul de la capacité de transfert totale et de la marge de fiabilité de transport - modèle applicable aux frontières belges pour les capacités annuelles et mensuelles.” 2009.
- [135] “Calculation methods - Elia.” [Online]. Available: <http://www.elia.be/en/products-and-services/cross-border-mechanisms/transmission-capacity-at-borders/calculation-methods>. [Accessed: 19-Feb-2018].
- [136] R. Dupin, A. Michiorri, and G. Kariniotakis, “Dynamic line rating day-ahead forecasts - cost benefit based selection of the optimal quantile,” pp. 122 (4 .)-122 (4 .), Jan. 2016.
- [137] K. Van den Bergh, E. Delarue, and W. D’haeseleer, “DC power flow in unit commitment models,” *TMF Work. Pap.-Energy Environ. Tech Rep*, 2014.
- [138] M. Nick, O. Alizadeh-Mousavi, R. Cherkaoui, and M. Paolone, “Security Constrained Unit Commitment With Dynamic Thermal Line Rating,” *IEEE Trans. Power Syst.*, vol. 31, no. 3, pp. 2014–2025, May 2016.
- [139] “Mixed-Integer Programming (MIP) Basics | Gurobi.” [Online]. Available: <http://www.gurobi.com/resources/getting-started/mip-basics>. [Accessed: 06-Oct-2017].
- [140] T. FICO, “Xpress Optimization Suite,” *Xpress-Optim. Ref. Man. Fair Isaac Corp.*, 2009.
- [141] J. F. Benders, “Partitioning procedures for solving mixed-variables programming problems,” *Numer. Math.*, vol. 4, no. 1, pp. 238–252, Dec. 1962.
- [142] R. Lincoln, *PyPower*. 2017.
- [143] R. D. Zimmerman, C. E. Murillo-Sánchez, and R. J. Thomas, “MATPOWER: Steady-state operations, planning, and analysis tools for power systems research and education,” *IEEE Trans. Power Syst.*, vol. 26, no. 1, pp. 12–19, 2011.
- [144] R. D. Zimmerman and C. E. Murillo-Sánchez, *Matpower Optimal Scheduling Tool MOST 1.0 User’s Manual*. .
- [145] A. Pagnetti, G. Delille, G. Malarange, A. Minaud, E. R&D–France, and E. R.-F. ERDF–France, “Probabilistic methods moving towards the field: a tool for DG connection studies featuring the alternatives to grid reinforcement,” in *Proc. CIRED Workshop*, 2014, p. 0188.

- 
- [146] C. Grigg *et al.*, “The IEEE Reliability Test System-1996. A report prepared by the Reliability Test System Task Force of the Application of Probability Methods Subcommittee,” *IEEE Trans. Power Syst.*, vol. 14, no. 3, pp. 1010–1020, Aug. 1999.
- [147] “ENTSO-E — European Network of Transmission System Operators,” *ENTSO-E — European Network of Transmission System Operators*. [Online]. Available: <https://rustyb.github.io/ee-bites/statistics/>. [Accessed: 08-Mar-2018].
- [148] F. Teng, R. Dupin, A. Michiorri, G. Kariniotakis, Y. Chen, and G. Strbac, “Understanding the Benefits of Dynamic Line Rating under Multiple Sources of Uncertainty,” *IEEE Trans. Power Syst.*, 2017.



**Annexe 1 - R. Dupin, A. Michiorri, G. Kariniotakis, “Dynamic Line Rating Day-Ahead Forecasts – Cost Benefit Based Selection of the Optimal Quantile”, CIRED workshop, 2016, Helsinki.**

---





reducing imbalance penalties. The optimal forecast in this application is not necessarily the one that minimises the Mean Absolute Percentage Error (MAPE), but rather the one that minimises financial losses.

If the costs  $\pi_{t+h}^+$  and  $\pi_{t+h}^-$  are independent from  $d_{t+h}^\tau$  and positive, the quantile minimizing this equation can be calculated analytically using formula in Equation (4):

$$\tau_{+h}^{opt} = \frac{\pi_{+h}^+}{\pi_{+h}^+ + \pi_{+h}^-} \quad (4)$$

### DLR Forecast optimised quantile

The method described above is here adapted to DLR forecasting. We consider that a quantile forecast of the DLR,  $\hat{Y}_{+h|t}^\tau$  can be calculated. In this case, both  $\hat{Y}_{+h|t}^\tau$  and  $d_{+h}^\tau$  are expressed in MVA. The DLR is considered as the thermal limit of the line, although this value should be reduced by taking into account other criteria due to grid limitations, for example: i) the limited size of balancing reserves on both sides of the line, ii) the risk of removing N-1 configurations in case a DLR forecast appears to be false, iii) the current stability limits, and iv) the thermal limits of other components, such as circuit breakers or transformers. However, for the sake of simplicity, these constraints are not considered in this study.

The following study is carried out for a line connecting two different electricity markets. The case study was designed to express simply the financial cost at both sides of the line due to errors related to DLR forecasting. As a reminder, as described in [12], a producer participating in an electricity market can go through four channels:

- The electricity futures market, on which long-term contracts on electricity bids are made.
- The day-ahead market, also called the spot market, on which a unique spot price is set depending on the proposed bids.
- The intraday market, on which the imbalances that occurred during the day can be corrected. This usually ends from 30 minutes to 2 hours before the time of delivery.
- Towards the end of the intraday market and the delivery time, possible imbalances are corrected during balancing by the transmission system operator. Positive and negative imbalances can have different costs.

The economic benefits associated with DLR forecasts are here considered to be dependent from the spot and imbalance costs. This involves assuming that the DLR forecast error has a different financial cost for positive and negative errors:

- If  $d_{+h}^\tau > 0$ , for a line connecting two areas with different spot electricity costs,  $C^1$  and  $C^2$  (€/MW),

the following cost is defined in Equation (5):

$$\pi_{+h}^+ = -|C_t^1 - C_t^2| \quad (5)$$

This cost is linked to the fact that a better forecast would have increased the economic benefits relative to the use of the line. It is assumed that the increased rating of the line has no impact on  $C_t^1$  and  $C_t^2$ .

- If  $d_{+h}^\tau < 0$ , the rating of the line is reduced to  $Y_{t+h}$ , and up and down reserves are activated in the two connected areas. If  $C_t^1 > C_t^2$ , it causes a cost described in Equation (6). In the opposite case, the indexes need to be swapped:

$$\pi_{+h}^- = (C_t^{imbalance\ 1^-} + C_t^{imbalance\ 2^+}) \quad (6)$$

where  $C_t^{imbalance\ 1^-}$  is the regulation cost for negative imbalances in the first area.  $C_t^{imbalance\ 2^+}$  is the regulation cost for positive imbalances in the second area. It is supposed that both these parameters are independent from  $d$ .

At this point, considering (4), (5) and (6), the quantile optimising the financial benefits from DLR forecast can be calculated as in Equation (7):

$$\tau_{opt} = \frac{|C^1 - C^2|}{|C^1 - C^2| + C_t^{imbalance\ 1^-} + C_t^{imbalance\ 2^+}} \quad (7)$$

### CASE STUDY

The test case considered here is a virtual line at the border of France and Belgium, connecting the two countries. It is located at the position (3.125°N, 50.375°E, only one point was considered in this study and not the whole length of the circuit), and was studied from 1st January 2014 to 31st December 2015. We considered that the line is equipped with a 175mm<sup>2</sup> Lynx conductor.

The spot prices for France were provided by EPEX and those for Belgium by BELPEX. The balancing cost data were provided by the two national transmission system operators, RTE and Elia.

The DLR was calculated every 12 hours at the studied position, using reanalysis data provided by the European Center for Medium range Weather Forecasts (ECMWF) and the CIGRE standard method for calculating DLR [2]. The parameters used were:

- The 10m East/West wind component  $Uf$  (m.s<sup>-1</sup>).
- The 10m North/South wind component  $Vf$  (m.s<sup>-1</sup>).
- The ambient temperature  $Tf$  (°C).
- The solar radiation  $S$  set equal to 0 W.m<sup>-2</sup>.

The DLR forecasts were generated using Numerical Weather Predictions (NWP) provided by ECMWF for the same parameters, at 4 positions close to the studied point. The prediction horizon  $h$  of the forecasts was equal to 24 hours. The forecasts were provided with a Quantile Regression Forest method (QRF) [13], which

was trained with the data from 2014. Data from 2015 was used for the evaluation.

## RESULTS

### DLR forecasts

Day-ahead DLR forecasts were provided every 12 hours for the studied case, and the 99 percentiles associated with the forecasted DLR were calculated. As an example, the result obtained for one month is shown in Figure 1.

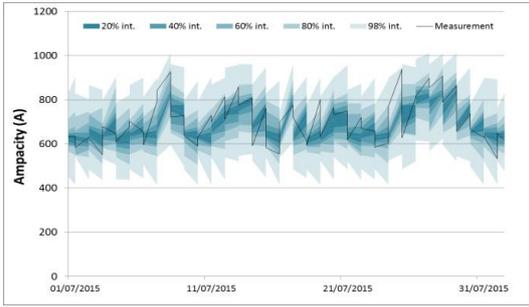


Figure 1. Consecutive day-ahead DLR forecasts from 01/07/2015 to 31/07/2015.

Using the MAPE, we can compare the deterministic performances of the model with the ones of a persistence model, whereby the forecast made at  $t$  for  $t + h$  is equal to the observation at  $t$ . A MAPE of 8.1% was calculated for the QRF, and of 11.4% for the persistence model.

### Optimised quantile

Two methods were proposed for the quantile selection:

- An arbitrarily selected quantile  $\tau_{\text{Arbitrary}}$ .
- A dynamically modified quantile in accordance with the spot prices, selected using Equation (7). Depending on the values of the balancing costs used, two quantiles are calculated:  $\tau_{\text{Spot}}$  with the mean balancing cost values of the same month during the previous year and  $\tau_{\text{Spot,Balancing}}$  with observed balancing costs at time  $t + h$ .

For the first method, the economic benefits linked to the current flowing through the lines were calculated for various quantiles, from 1% to 100%. As seen on Figure 2, the benefits were optimised using the 14%-quantile. This evaluation was made with the formula in Equation (8).

$$z = \min(\hat{Y}_{t+h|t}^{\tau}, Y_{t+h}) * |C_t^{\text{SPOT},1} - C_t^{\text{SPOT},2}| + \max(\hat{Y}_{t+h|t}^{\tau} - Y_{t+h}, 0) * (C_t^{\text{imbalance } 1^-} + C_t^{\text{imbalance } 2^+}) \quad (8)$$

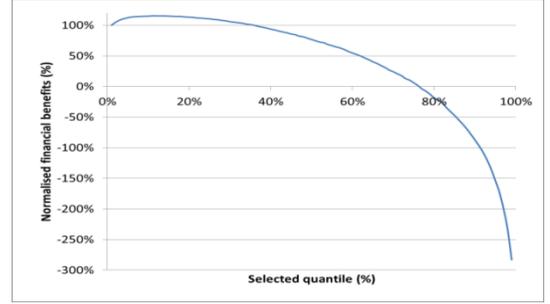


Figure 2. Benefits with an arbitrarily selected quantile

With the second method, the quantiles were calculated for 2015. The mean values for each month were provided in Table 1.

Parameter	$\tau_{\text{Spot}}$	$\tau_{\text{Spot,Balancing}}$
January	2.5%	2,6%
February	2.8%	2,1%
Mars	4.1%	3,8%
April	10.9%	10,8%
May	12.9%	14,7%
June	8.7%	8,0%
July	7.4%	8,0%
August	10.2%	8,8%
September	15.2%	18,2%
October	9.3%	8,6%
November	3.9%	4,9%
December	2.5%	7,6%
<b>Mean value</b>	<b>7.5%</b>	<b>8.2%</b>

Table 1. Mean optimal quantile selected during 2015.

In order to evaluate the financial benefit of the proposed approaches, 5 cases were tested and compared:

1. The 1%-quantile DLR forecasts were used.
2. The 50%-quantile DLR forecasts were used.
3. The  $\tau_{\text{Arbitrary}}$ -quantile DLR forecasts were used.  $\tau_{\text{Arbitrary}}$  is set as equal to 14%.
4. The  $\tau_{\text{Spot}}$ -quantile DLR forecasts were used.
5. The  $\tau_{\text{Spot,Balancing}}$ -quantile DLR forecasts were used.

The benefits achieved during 2016 for the five cases were compared and the results are shown in Table 2. The results were normalised with respect to the benefits achieved using an arbitrary 1% quantile.

Case	Financial benefits respect to 1%
1%-forecasts	100.0%
50%-forecasts	76.7%
$\tau_{\text{Arbitrary}}$ -forecasts	115.1%
$\tau_{\text{Spot}}$ forecasts	115%
$\tau_{\text{Spot,Balancing}}$ forecasts	120.2%

Table 2. Normalized benefits for cases 1 to 5

The analysis of these results leads to the following considerations:

- Using an arbitrary 50%-quantile of the forecasts was counter-productive.
- Increasing the chosen quantile from 1% to 14% increased the financial benefits by 15.1%.

- The choice of a variable optimal quantile taking into account spot prices and historical average balancing costs increased the benefits by 15.0%. If real balancing costs at  $t+h$  were taken into account, the benefits increased by 20.2%.

## CONCLUSIONS

The study presented a methodology for selecting the optimal quantile to determine a forecast DLR obtained using probabilistic methods. The methodology is based on a cost-benefit analysis and the aim is to use it, along with other criteria, to optimize day-ahead DLR forecasts.

The methodology proposed was tested on a test case describing a circuit on which DLR is applied, connecting two electricity market zones with different prices and balancing costs. This case is simple, and more complex situations should be studied further, but the observed results are promising and show potential benefits compared to the standard method using an arbitrarily selected low quantile.

It should be stressed that whilst the choice of the quantile is not influenced by the actual value of the rating, the financial benefit calculated is. This means that the results presented in Table 2 are more dependent on the data used, and in particular on the meteorological data used for rating calculations and forecasts, which are obtained from 12-hour reanalysis. The use of more precise historical weather data is expected to increase the precision of the forecasts and the results, but also to increase the variability of the rating. Moreover, this methodology based on a simple cost-benefit analysis does not take into account other DLR limitations, which should be included in further studies on adapting DLR forecasts to grid conditions. Other criteria, such as the costs associated with increased risks, could be considered when evaluating DLR forecast errors.

## ACKNOWLEDGMENT

The following companies are acknowledged: ECMWF for access provided to the weather forecasts and reanalysis data; EPEX and BELPEX for the historical data on spot costs; RTE and Elia for the access provided to the historical data on balancing costs.

## REFERENCES

- [1] IEEE, "Standard for Calculating the Current-Temperature Relationship of Bare Overhead Conductors," Transmission and distribution committee of the IEEE Power Engineering Society IEEE Std 738-1993, 1993.
- [2] W. CIGRE, "12, Thermal Behaviour of Overhead Conductors, Tech," ed: Brochure, 2002.
- [3] A. Michiorri, H.-M. Nguyen, S. Alessandrini, J. B. Bremnes, S. Dierer, E. Ferrero, *et al.*, "Forecasting for dynamic line rating," *Renewable and Sustainable Energy Reviews*, vol. 52, pp. 1713-1730, 2015.
- [4] M. Khaki, P. Musilek, J. Heckenbergerova, and D. Koval, "Electric power system cost/loss optimization using dynamic thermal rating and linear programming," in *Electric Power and Energy Conference (EPEC), 2010 IEEE*, 2010, pp. 1-6.
- [5] C. J. Wallnerstrom, Y. Huang, and L. Soder, "Impact From Dynamic Line Rating on Wind Power Integration," *Smart Grid, IEEE Transactions on*, vol. 6, pp. 343-350, 2015.
- [6] D. M. Greenwood and P. C. Taylor, "Investigating the impact of real-time thermal ratings on power network reliability," *Power Systems, IEEE Transactions on*, vol. 29, pp. 2460-2468, 2014.
- [7] T. Ringelband, P. Schäfer, and A. Moser, "Probabilistic ampacity forecasting for overhead lines using weather forecast ensembles," *Electrical Engineering*, vol. 95, pp. 99-107, 2013.
- [8] X. Sun, P. B. Luh, K. W. Cheung, and W. Guan, "Probabilistic forecasting of dynamic line rating for over-head transmission lines," in *Power & Energy Society General Meeting, 2015 IEEE*, 2015, pp. 1-5.
- [9] H.-M. Nguyen, J.-L. Lilien, and P. Schell, "Dynamic line rating and ampacity forecasting as the keys to optimise power line assets with the integration of res. The European project Twenties Demonstration inside Central Western Europe," in *Electricity Distribution (CIRED 2013), 22nd International Conference and Exhibition on*, 2013, pp. 1-4.
- [10] "Final report on NETFLEX Demo," Twenties European Project, 2013.
- [11] P. Pinson, C. Chevallier, and G. N. Kariniotakis, "Trading wind generation from short-term probabilistic forecasts of wind power," *Power Systems, IEEE Transactions on*, vol. 22, pp. 1148-1156, 2007.
- [12] R. Madlener and M. Kaufmann, "Power exchange spot market trading in Europe: theoretical considerations and empirical evidence," *OSCOGEN (Optimisation of Cogeneration Systems in a Competitive Market Environment)-Project Deliverable*, vol. 5, 2002.
- [13] N. Meinshausen, "Quantile Regression Forest," *Journal of Machine Learning Research*, vol. 7, pp. 983-999, 2006.

**Annexe 2 - F. Teng, R. Dupin, A. Michiorri, G. Kariniotakis, Y. Chen, and G. Strbac, 'Understanding the Benefits of Dynamic Line Rating under Multiple Sources of Uncertainty', IEEE Trans. Power Syst., 2017.**

---



# Understanding the Benefits of Dynamic Line Rating under Multiple Sources of Uncertainty

Fei Teng, *Member, IEEE*, Romain Dupin, Andrea Michiorri, George Kariniotakis, *Senior Member, IEEE*, Yanfei Chen and Goran Strbac, *Member, IEEE*

**Abstract**— This paper analyses the benefits of dynamic line rating (DLR) in the system with high penetration of wind generation. A probabilistic forecasting model for the line ratings is incorporated into a two-stage stochastic optimization model. The scheduling model, for the first time, considers the uncertainty associated with wind generation, line ratings and line outages to co-optimize the energy production and reserve holding levels in the scheduling stage as well as the re-dispatch actions in the real-time operation stage. Therefore, the benefits of higher utilization of line capacity can be explicitly balanced against the costs of increased holding and utilization of reserve services due to the forecasting error. The computational burden driven by the modelling of multiple sources of uncertainty is tackled by applying an efficient filtering approach. The case studies demonstrate the benefits of DLR in supporting cost-effective integration of high penetration of wind generation into the existing network. We also highlight the importance of simultaneously considering the multiple sources of uncertainty in understanding the benefits of DLR. Furthermore, this paper analyses the impact of different operational strategies, the coordination among multiple flexible technologies and installed capacity of wind generation on the benefits of DLR.

**Index Terms**—Dynamic line rating, probabilistic forecasting, stochastic programming, wind generation.

## NOMENCLATURE

### A. Constants (Written in Normal Font)

$D_n$	Demand in node $n$ (MW)
$\underline{F}_l / \bar{F}_l$	Minimum / Maximum capacity of AC transmission line $l$ (MW)
$\bar{H}_g^{up} / \bar{H}_g^{do}$	Maximum reserve up / down holding amount of conventional generator $g$ (MW)
$\underline{P}_g / \bar{P}_g$	Minimum / Maximum capacity of conventional generator $g$ (MW)
$\bar{WP}_{s,w}$	Maximum available output of wind generator $w$ in scenario $s$ (MW)
$X_l$	Reactance of AC line $l$ (p.u.)
$\text{Voll}_n$	Value of lost load at node $n$ [£/MWh].

$\pi\text{fix}_g$	Fixed/Commitment cost of conventional generator $g$ (£/MW/h)
$\pi\text{fuel}_g$	Fuel cost of conventional generator $g$ (£/MWh)
$\pi\text{rdo}_g$	Utilization cost of reserve down service from conventional generator $g$ (£/MWh)
$\pi\text{rup}_g$	Utilization cost of reserve up service from conventional generator $g$ (£/MWh)
<i>B. Variables (Written in Italic Font)</i>	
$f_{s,l}$	Power flow of AC line $l$ at scenario $s$ (MW)
$I_g$	Binary variable. 1 means conventional generator $g$ is committed
$ll_{s,n}$	Loss of load in node $k$ at operating state $s$ [MW]
$P_g$	Output of conventional generator $g$ (MW)
$R_{s,g}^{up}/R_{s,g}^{do}$	Utilized reserve up /down service from conventional generator $g$ at scenario $s$ (MW)
$WP_{s,w}$	Output of wind generator $w$ at scenario $s$ (MW)
$\Delta_{s,l}$	Ratio of DLR to SLR for line $l$ at scenario $s$ (p.u.)
$\theta_{s,n}$	Voltage angle of node $n$ at scenario $s$ (rad)

### C. Set Related Constants (Written in Italic Font)

$G_n$	Set of conventional generators in node $n$
$I_n$	Set of lines with positive power flow to node $n$
$n_1(l)$	First end node of line $l$
$n_2(l)$	Second end node of line $l$
$N_g$	Total number of conventional generators
$N_l$	Total number of transmission lines
$N_n$	Total number of nodes
$N_s$	Total number of scenarios
$N_w$	Total number of wind generators
$O_n$	Set of lines with positive power flow from node $n$
$W_n$	Set of wind generators in node $n$ .

## I. INTRODUCTION

High penetration of renewable energy resources (RES) are expected to be integrated into the future power systems. However, there are two main challenges associated with such massive integration. Firstly, most of RES are intermittent, leading to an increased need on the ancillary services [1]. Novel stochastic operation frameworks, along with flexible technologies (such as energy storage), have been proposed to accommodate the intermittence of RES. Secondly, RES is usually located in the remote areas, and hence large-scale

F. Teng, YF. Chen and G. Strbac are with Department of Electrical and Electronic Engineering, Imperial College London, London, SW7 2AZ, U.K. (email: [f.teng@imperial.ac.uk](mailto:f.teng@imperial.ac.uk), [yanfei.chen11@imperial.ac.uk](mailto:yanfei.chen11@imperial.ac.uk), [g.strbac@imperial.ac.uk](mailto:g.strbac@imperial.ac.uk).)

R. Dupin, A. Michiorri, G. Kariniotakis are with with MINES ParisTech, PSL Research University, PERSEE - Centre for Processes, Renewable Energies and Energy Systems CS 10207 rue Claude Daunesse, 06904 Sophia Antipolis Cedex, France. (email: [romain.dupin@mines-paristech.fr](mailto:romain.dupin@mines-paristech.fr), [andrea.michiorri@mines-paristech.fr](mailto:andrea.michiorri@mines-paristech.fr), [georges.kariniotakis@mines-paristech.fr](mailto:georges.kariniotakis@mines-paristech.fr).)

network expansion is required to transfer the low-carbon electricity to the load centre [2]. This not only requires large amount of investment, but also takes long time to develop, potentially limiting the penetration of RES in the short term.

Dynamic line rating (DLR) [3] is an alternative technology to enhance the transfer capability of the existing network. Traditionally, static line ratings (SLR) are utilized, while the actual line capacity depends on various factors that change in time, such as solar radiation and wind condition [4]. SLR causes significant under-utilization of the actual network transfer capability. The application of DLR can effectively alleviate network congestion, lower the operating costs and RES curtailment in the short term and thus postpone and reduce the need of network reinforcement and support the high penetration of RES in the long term. Therefore, it is important to understand how DLR can be optimally integrated into the system operation and to what extent it can facilitate the cost-effective integration of RES [5].

The authors in [6] propose a general DLR calculation model and carry out cost-benefit analysis for the application of DLR. An “N-1” security constrained dispatch model is presented in [7] with the consideration of DLR and the results suggest that DLR reduces RES curtailment and dispatch cost with the expense of higher computational time for the scheduling problem. The study in [8] shows that the implementation of DLR to a 132kV line between Skegness and Boston can enable 20% to 50% more wind generation to be connected. The authors in [9] propose a distribution network investment model with DLR option to demonstrate the role of DLR in supporting distributed energy resources. Combined analysis of DLR and demand response in [10] identifies the synergy between these technologies. The authors in [11] apply a security constrained AC dispatch model to investigate the benefit of DLR in enhancing the system security.

However, like other weather-dependent elements, the line ratings cannot be perfectly forecasted in advance, which is not explicitly considered in the above literatures. The authors in [12] highlight the need to develop DLR forecast models to facilitate its application and present a state-of-art review on the forecasting techniques. Machine learning techniques [13] and ensemble weather forecast [14] are among the most widely used method in the forecasting of DLR. A novel probabilistic DLR forecasting method is developed in [15] to derive the expected value and important percentiles of ratings.

The forecasting error of DLR imposes significant challenges on its optimal implementation in the system operation. A cost-benefit based optimal quantile selection approach is developed in [23] and the selected quantile can be used as the input into the system scheduling model. The authors in [16] propose a novel robust congestion management model to optimally use DLR on critical lines, while keeping the risk of overloading below certain level. However, this model relies on a simple binary line rating forecast and requires pre-selected risk level. The work in [17] incorporates DLR with forecasting error distribution into a robust system dispatch framework, but only considers the uncertainty related to DLR forecast. Two-stage stochastic

programming is the most widely used method to coordinate day-ahead dispatch and real-time re-dispatch actions under uncertainty [18]. However, none of existing stochastic model directly incorporates DLR into the optimal system operation when simultaneously considering forecasting errors of DLR and wind generation as well as line outages. Furthermore, in addition to DLR, there are multiple flexible network technologies (e.g. FACTs). In the literature and industrial applications, there is lack of understanding on how DLR can be optimally utilized to support high penetration of RES when considering the interaction among multiple sources of uncertainty and the coordination among multiple flexible technologies.

In this context, this paper extends a two-stage stochastic optimization model to include the probabilistic forecasts of DLR so that the model can co-optimize the energy and reserve holding levels in the scheduling stage as well as the re-dispatch actions in the real-time operation stage. Therefore, the benefit of higher utilization of line capacity can be explicitly balanced against the cost of increased holding and utilization of reserve services and/or demand shedding. The key contributions can be summarised as:

- 1) this paper presents a stochastic assessment framework with the probabilistic forecasts of DLR, which, for the first time, enables the understanding of optimal utilization of DLR with consideration of the interaction among multiple sources of uncertainty (DLR, wind outputs and line outages) and the coordination among multiple flexible network technologies (DLR and FACTs).
- 2) to tackle the computational burden driven by the large number of integer variables associated with FACTs devices and the large number of scenarios driven by the multiple sources of uncertainty, we investigate the minimal value of “big-M” used in the disjunctive approach and apply an iterative filtering model to select a subset of the scenarios to represent the multiple sources of uncertainty.
- 3) comprehensive analysis is carried out to understand the benefits of DLR in the system with high penetration of wind generation under different operational strategies and to investigate how the correlations among multiple sources of uncertainty as well as the coordination with FACTs devices may affect the benefits of DLR.

The paper is organized as follows. Section II presents the modelling framework for DLR and its forecasting. Section III introduces the two-stage stochastic scheduling model that is used to optimize the system operation with probabilistic forecasts of DLR. The benefits of DLR are firstly demonstrated through a simple 2-busbar system in Section IV and a study on IEEE 24 bus RTS system is then presented in Section V. Final conclusions are discussed in section VI.

## II. DYNAMIC LINE RATING

### A. Modelling of Dynamic Line Rating

The current carrying capacity of overhead line conductors is determined by the maximum sag, which guarantees the minimum allowed clearance. Conductors lose tensile strength and hence increase their sag with the increased temperature,

as summarised in (1) with the link between tensile strength  $F_t$  and vertical sage  $L_{sag}$  and (2) with the relation between conductor temperature  $T_c$  and axial tensile strength  $F_t$ .

$$L_{sag} \approx \frac{F_p L_{span}^2}{8F_t} \quad (1)$$

$$E_c A_c \beta_c T_{c,i} + \frac{E_c A_c}{24} \left( \frac{F_{p,i} L_{span}}{F_{t,i}} \right)^2 - F_{t,i} = K \quad (2)$$

where  $L_{sag}$ [m] is sag,  $F_p$ [N] is linear weight of the conductor,  $F_t$ [N] is tensile strength of the conductor,  $L_{span}$ [m] is length of the span,  $E_c$ [Pa] is Young's modulus,  $A_c$ [m<sup>2</sup>] is conductor cross sectional area,  $\beta_c$ [K<sup>-1</sup>] is conductor's expansion factor,  $T_c$ [K] is conductor's temperature and  $K$ [N] is a constant value.

This shows that the sag can be limited by constraining the conductor's temperature  $T_c$ . In the steady state, this parameter in turn is dependent on the thermal equilibrium between the heat dissipated by joule effect in the conductor and the heat exchange on its surface, as shown in Equation (3), usually represented in the form (4).

$$q_c + q_r = q_s + q_l \quad (3)$$

$$I = \sqrt{\frac{q_c + q_r - q_s}{R}} \quad (4)$$

where  $I$  [A] is maximum allowable current,  $q_c$  [W/m] is convective cooling,  $q_r$  [W/m] is radiative cooling,  $q_s$ [W/m] is solar heating and  $R$  [ $\Omega$ /m] is conductor resistance.

As seen above, these terms depend on conductor's temperature and environmental parameters such as air temperature, wind speed and solar radiation. Details on the calculation on each one of these terms can be found in [6]. Due to the non-linear relations between conductor rating and wind speed and the variability of environmental parameters, it is common practice to use static ratings based on conservative assumptions. This has two main drawbacks: the use of a small part of the circuits' current carrying capacity and the presence of high risk situations where real ratings are below the SLR.

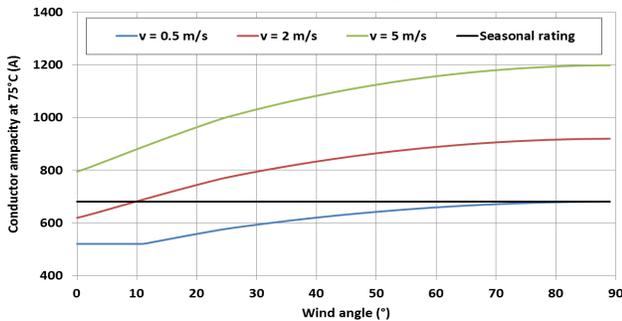


Fig.1 Relation among wind speed, wind direction and conductor ampacity

For an example of a Lynx cable with a maximum temperature of 75°C and according to the CIGRE standard, Fig.1 shows an illustration of the relationship between conductor rating, wind speed and wind direction, the ambient temperature being set to 20°C and the global solar radiation being null. These are compared with the summer static seasonal rating. The static seasonal rating is the current standard adopted by network operators for setting line maximum ampacity and is calculated considering static

values for weather parameters. In this case the values used are: 0.5 [m/s] for wind speed, wind direction perpendicular to the axis of the conductor, 20 [°C] for air temperature and 0 [W/m<sup>2</sup>] for solar radiation.

### B. Forecast for Dynamic Line Rating

Like other weather-dependent elements, the actual line ratings cannot be perfectly forecasted in advance, which explains the slow take-up rate of this technology. Due to the strong dependence of DLR on the weather conditions, the procedure proposed for DLR forecasts is similar to the approach commonly used for renewable energy production forecast, i.e. based on a mix of statistical methods and meteorological forecasts. The problem of forecasting is treated as a regression problem, where it is to be found a function  $f_h$  able to provide an ampacity forecast  $\hat{Y}_{t+h|t}$  at time  $t+h$  knowing a set of information  $X_t$  at time  $t$ .

The line rating forecast  $\hat{Y}_{t+h|t}$  at a time  $t$  for a horizon  $t$ , considering a series of explanatory variables  $X_t$  is given by:

$$\hat{Y}_{t+h|t} = f_h(X_t) \quad (5)$$

where  $f_h$  returns the random variable  $Y_{t+h}$  with an explicit distribution. Given that the conductor ampacity is not observable, we consider it as a nonlinear function  $g(\cdot)$  of exogenous variable  $X_t$ . This function does not depend on the time step and can be calculated as detailed in [4,6].

System operators consider security constraints in a conservative way, and so the probability of having a forecast higher than the observation must be set as equal to a value  $\tau$  defined by the operator as specified in (6). Such forecasts can be provided through various methods, directly providing a quantile forecast  $\hat{Y}_{t+h|t}^\tau$  or a probability density function  $\hat{f}_h$  used for its calculation.

$$P(\hat{Y}_{t+h|t} > Y_{t+h}) = \tau \quad (6)$$

In this work, DLR forecasts are calculated with a Quantile Regression Forest algorithm [19], a machine learning method successfully used for probabilistic ampacity forecasts [13]. In this method,  $k$  different decision trees are generated and trained on a randomly generated dataset through bootstrap aggregation. After this at each split of the tree, features are selected through a random features' subset. The model calculates the  $k$  different ampacity values describing a distribution of results from what is possible to calculate an average or the values of different quantiles.

An example of the forecasts is presented in Fig.2. Historical records for wind and other weather parameters relevant for the calculation of DLR relative to southern Sweden for the year 2010 have been used. The records contain hourly measurements of wind speed, wind direction, solar radiation and air temperature. They are coupled with hourly Numerical Weather Prediction for horizon up to 48h for the same variables and updated once a day. These forecasts are obtained from the European Centre for Medium-Range Weather Forecasts.

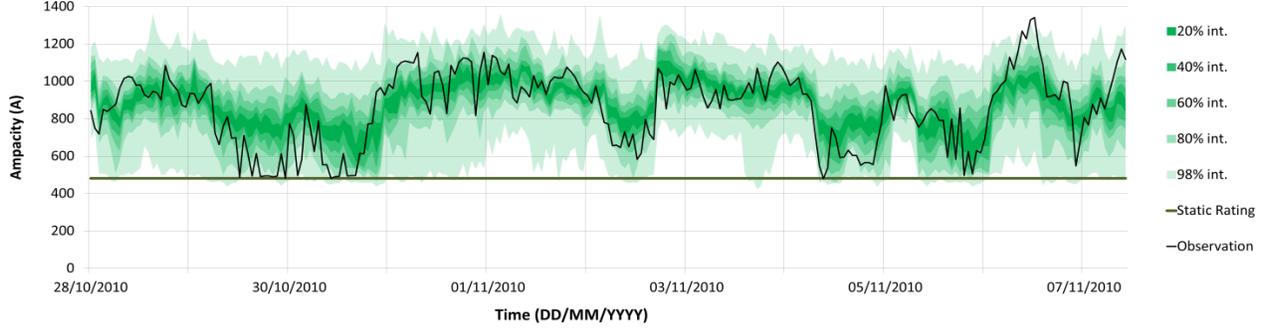


Fig. 2: Example of Dynamic Line Rating observations and day-ahead probabilistic forecasts

### III. ASSESSMENT APPROACH: TWO-STAGE STOCHASTIC OPTIMIZATION MODEL

A two-stage stochastic optimization model is proposed based on the scenarios that combine the possible realizations of line ratings, wind levels and line outages. The corrective cost-benefit based framework incorporates control actions from all sources (generators, demand and network) during pre and post-fault conditions. The aim of this framework is to efficiently balance costs of generation dispatch (including energy supply and reserve holding) and costs of corrective control actions (including reserve utilization and post-fault demand shedding).

The objective function of the probabilistic optimization is introduced in (7), where “ $t$ ” is the time duration of each selected operating condition and “ $\rho_s$ ” represents the probability of the selected scenario “ $s$ ”. The model is formulated as a mixed integer linear programming problem. The first components represent the dispatch costs (variable and fixed/commitment cost of conventional generators) in the scheduling stage, and the second and third cost components represent the costs of corrective control actions from generation side (reserve up/down services activation) and demand side (post-fault demand shedding) in each of the potential realizations.

$$\text{Min} \left\{ \begin{array}{l} t \cdot \sum_{g=1..Ng} \{ \text{pfuel}_g \cdot P_g + \text{pfix}_g \cdot I_g \} + \\ t \cdot \sum_{\substack{g=1..Ng \\ s=2..Ns}} \rho_s \cdot \{ \text{prup}_g \cdot R_{s,g}^{\text{up}} - \text{prdo}_g \cdot R_{s,g}^{\text{do}} \} + \\ t \cdot \sum_{\substack{n=1..Nn \\ s=2..Ns}} \rho_s \cdot \{ \text{Voll}_n \cdot I_{s,n} \} \end{array} \right\} \quad (7)$$

The optimization problem is subject to the following constraints. Wind generator output (8) is a decision variable through each node of the scenario tree. Generation capacity boundary constraint is formulated in (9). The availability of reserve provision is constrained by the commitment decisions and physical limits of conventional generation, as in (10)-(16). Power flows in the network are calculated in (17)-(18), while power balance constraint containing wind generator for each node is given in (19).

$$0 \leq WP_{s,g} \leq \overline{WP}_{s,g} \quad \forall s = 2..Ns \quad \forall g = 1..Nw \quad (8)$$

$$P_g \cdot I_g \leq P_g \leq \overline{P}_g \cdot I_g \quad \forall g = 1..Ng \quad (9)$$

$$H_g^{\text{up}} \leq \overline{H}_g^{\text{up}} \cdot I_g \quad \forall g = 1..Ng \quad (10)$$

$$H_g^{\text{do}} \leq \overline{H}_g^{\text{do}} \cdot I_g \quad \forall g = 1..Ng \quad (11)$$

$$H_g^{\text{up}} \leq \overline{P}_g - P_g \quad \forall g = 1..Ng \quad (12)$$

$$H_g^{\text{do}} \leq P_g - \overline{P}_g \quad \forall g = 1..Ng \quad (13)$$

$$0 \leq R_{s,g}^{\text{up}} \leq H_g^{\text{up}} \quad \forall s = 2..Ns, g = 1..Ng \quad (14)$$

$$0 \leq R_{s,g}^{\text{do}} \leq H_g^{\text{do}} \quad \forall s = 2..Ns, g = 1..Ng \quad (15)$$

$$R_{s=1,g}^{\text{up}} = R_{s=1,g}^{\text{do}} = 0 \quad s = 1, \forall g = 1..Ng \quad (16)$$

$$f_{s,l} = \frac{\theta_{s,n_1(l)} - \theta_{s,n_2(l)}}{X_l} \quad \forall s, l = 1..Nl \quad (17)$$

$$\theta_{s,n=\text{ref}} = 0 \quad \forall s \quad (18)$$

$$\begin{aligned} & \sum_{g \in Gn} (P_g + R_{s,g}^{\text{up}} - R_{s,g}^{\text{do}}) + \sum_{w \in Wn} WP_{s,g} + \sum_{l \in Ln} (f_{s,l} + P_{s,l}^{\text{SC}}) \\ & - \sum_{l \in On} (f_{s,l} + P_{s,l}^{\text{SC}}) \\ & = D_n - I_{s,n} \quad \forall s, n = 1..Nn \quad (19) \end{aligned}$$

Lines without and with DLR are contained in set A and B, respectively. The traditional line rating constraint is introduced in (20), while the constraint (21) is utilized to represent the lines equipped with DLR. In the case of line outage, constraint (22) is imposed.

$$\underline{F}_l \leq f_{s,l} + P_{s,l}^{\text{SC}} \leq \overline{F}_l \quad \forall s, l \text{ available}, l \in A \quad (20)$$

$$\underline{F}_l \cdot \Delta_{s,l} \leq f_{s,l} + P_{s,l}^{\text{SC}} \leq \overline{F}_l \cdot \Delta_{s,l} \quad \forall s, l \text{ available}, l \in B \quad (21)$$

$$f_{s,l} + P_{s,l}^{\text{SC}} = 0 \quad \forall s, l \text{ outage} \quad (22)$$

With the disjunctive approach, power flow modified by series compensation (SC) can be determined by:

If  $\Delta\theta_{s,l}$  is positive, then

$$\varphi_l \cdot \Delta\theta_{s,l} \leq P_{s,l}^{\text{SC}} \leq \eta_l \cdot \Delta\theta_{s,l} \quad \forall s, l \in L \quad (23)$$

If  $\Delta\theta_{s,l}$  is negative, then

$$\eta_l \cdot \Delta\theta_{s,l} \leq P_{s,l}^{\text{SC}} \leq \varphi_l \cdot \Delta\theta_{s,l} \quad \forall s, l \in L \quad (24)$$

To linearize this, “big-M” approach is applied to transfer (23)-(24) into 4 mixed integer linear constraints (25)-(28):

$$P_{s,l}^{\text{SC}} \leq \eta_l \cdot \Delta\theta_{s,l} + Y_{s,l} \cdot M_{s,l} \quad \forall s, l \in L \quad (25)$$

$$P_{s,l}^{\text{SC}} \geq \varphi_l \cdot \Delta\theta_{s,l} - Y_{s,l} \cdot M_{s,l} \quad \forall s, l \in L \quad (26)$$

$$P_{s,l}^{\text{SC}} \geq \eta_l \cdot \Delta\theta_{s,l} - (1 - Y_{s,l}) \cdot M_{s,l} \quad \forall s, l \in L \quad (27)$$

$$P_{s,l}^{\text{SC}} \leq \varphi_l \cdot \Delta\theta_{s,l} + (1 - Y_{s,l}) \cdot M_{s,l} \quad \forall s, l \in L \quad (28)$$

where  $\eta_l = \frac{\overline{X}_l^{\text{SC}}}{X_l \cdot (X_l - \overline{X}_l^{\text{SC}})}$ ,  $\varphi_l = \frac{X_l^{\text{SC}}}{X_l \cdot (X_l - X_l^{\text{SC}})}$ ,  $\Delta\theta_{s,l} = (\theta_{s,k_1(l)} - \theta_{s,k_2(l)})$  and  $Y_{s,l}$  is a binary variable.

The parameter " $M_{s,l}$ " is a sufficient large number. However, inappropriate selection of  $M_{s,l}$  may lead to long calculation time and limit the application of the model. Hence a minimum value of  $M_{s,l}$  is investigated to accelerate the optimization. When  $\Delta\theta_{s,l}$  is positive and  $Y_{s,l}$  is 0, in order to guarantee only (25) and (26) are activated, the right-hand side (RHS) of (28) must be bigger than the RHS of (25), and the RHS of (27) must be smaller than the RHS of (26). Consequently, (29) can be deduced as

$$(\eta_l - \psi_l) \cdot \Delta\theta_{s,l} \leq M_{s,l} \quad (\Delta\theta_{s,l} > 0) \quad \forall s, l \in L \quad (29)$$

Similarly, when  $\Delta\theta_{s,l}$  is negative and  $Y_{s,l}$  is 1, in order to only activate (27) and (28), the following constraint needs to be met:

$$(\psi_l - \eta_l) \cdot \Delta\theta_{s,l} \leq M_{s,l} \quad (\Delta\theta_{s,l} < 0) \quad \forall s, l \in L \quad (30)$$

Combine (29) and (30), the range of  $M_{s,l}$  can be obtained:

$$(\eta_l - \psi_l) \cdot |\Delta\theta_{s,l}| \leq M_{s,l} \quad \forall s, l \in L \quad (31)$$

Assume  $\Delta\theta_{s,l} = f_{s,l} \cdot (X_l - X_{s,l}^{SC})$  is used to calculate the power flow over the line installed with SC. If  $X_{s,l}^{SC} = \underline{X}_l^{SC} = -\delta \cdot X_l$ , where  $\delta$  is the maximum SC degree of compensation, then the positive maximum value of  $\Delta\theta_{s,l}$  is  $\bar{f}_{s,l} \cdot (1 - (-\delta)) \cdot X_l$ . Since  $(\eta_l - \psi_l) > 0$ , the minimum  $M_{s,l}$  is hence  $\frac{2\delta}{1-\delta} \cdot \bar{f}_{s,l}$ .

In the system with large amount of DLR devices, significantly increased number of scenarios are required to represent the multiple sources of uncertainty. This leads to high computational burden and may potentially prevent the implementation of DLR in the large scale system. Consequently, an extended filtering model based on [21] is applied in this paper to select a subset of scenarios so that the balance between computational time and optimality can be achieved. The fundamental idea is to select the scenarios that have high impact on the objective function for a given dispatch and hence may lead to a change of dispatch decision.

The proposed modelling framework can be executed iteratively by the following steps:

- 1). Input the weather forecasts into the proposed DLR forecasting model and obtain the associated DLR forecasts;
- 2). Define the full set of scenarios through combining DLR forecasts, wind forecasts as well as line outages; the initial subset is also selected;
- 3). Run the two-stage stochastic optimization framework based on the selected subset;
- 4). Calculate the probability weighted costs for all the scenarios with respect to scheduling decisions from step (3); this step is carried out by multi-threading parallel processing;
- 5). Rank the scenarios that are not in the selected subset with a descending order based on the calculated costs.
- 6). If the total cost of the scenarios, that are not in the selected subset, is higher than the pre-set tolerance, select and add the first 'm' scenarios with highest costs into the subset, and go to step (3); or, the algorithm terminates;

FICO Xpress v7.8 [22] is used on a server with two Intel Xeon E5-2687W processors and 512 GB of RAM to implement this algorithm.

#### IV. SMALL-SCALE SYSTEM STUDY

To demonstrate the impact of DLR on the system operation, the two-stage stochastic scheduling model is firstly applied in a simple 2-busbar system, where the line outage is also neglected. There are four conventional generators (G1-G4) located in node 1, two conventional generators (G5-G6) located in node 2 and a wind farm with capacity of 70 MW located in node 2. The physical limits and cost information for the generators are summarised in TABLE I. In addition, 70 MW demand is located in the node 1, while a transmission line with DLR of 26 MW links these two nodes. The value of lost load is set to be 30 k£/MWh.

TABLE I TWO-NODE SYSTEM'S GENERATION AND NETWORK DATA

Generator	Capacity	Minimum Generation	Ramp up/down	Fuel	Reserve Utilization	Fixed
	MW			£/MWh		£/MW/h
G1	20	7	13	70	70	600
G2	15	5	10	50	50	300
G3	15	5	10	50	50	300
G4	15	5	10	50	50	300
G5	5	1	3	30	30	400
G6	12	3	10	15	15	50
W1	70	0	0	0	0	0

This case study considers two sources of uncertainty, forecasting errors of DLR and wind generation. The expected wind production is assumed to 50% of the installed capacity and the forecasting error is assumed to follow a normal distribution with 0.2 standard deviation. 9 scenarios are generated to describe the distribution of wind forecasting. Table II presents a sample of the probabilistic forecasts of DLR. In the base case analysis, the two forecasting errors are assumed to be independent and hence there are in total 81 scenarios to be considered.

TABLE II DYNAMIC LINE RATING SCENARIOS

Rating over SLR	1	1.1	1.2	1.3	1.4	1.5	1.6	1.7	1.8
Probability (%)	0.5	4	12	15	40	20	5	3	0.5

##### A. Benefits of DLR

To understand the benefits of DLR, three different cases are compared:

- 1) SLR: No DLR monitoring stations are deployed. Hence, SLR strategy is used in both scheduling and operation phases. This approach represents the counterfactual case, against which the benefits of DLR can be assessed.
- 2) Real-time only DLR: DLR monitoring stations are assumed to be installed, but the forecast of DLR is not available. Therefore, SLR is applied in the scheduling phase, while DLR is allowed by using the data from monitoring stations in the real-time operation.
- 3) Fully-optimized DLR: DLR monitoring stations are assumed to be installed and the forecast of DLR is also available. DLR is therefore adopted in both the scheduling and the real-time operation phases.

The results in TABLE III show that the implementation of DLR in real-time only reduces the operation cost by 166 K£ and wind curtailment by 6 MW, while under the fully-optimized case, the operation cost saving of 315 K£ and wind curtailment reduction of 6 MW can be achieved.

The real-time only DLR case has the same dispatch decision as SLR case, but the extra available capacity from DLR in the real-time operation allows accommodating more wind energy to replace high cost generators in Node 1. The expected wind curtailment is reduced by three times. Negative re-dispatch cost in Real-time only DLR is achieved through utilizing reserve down services in real time. In this case, the expected utilization of transmission line is increased from 26 MW to 32.4 MW. However, the dispatch decision with SLR leaves the low-cost generators G6 off-line, which limits the further utilization of DLR in the real time even when extra capacity becomes available.

For the fully optimised case, the optimal flow over the transmission line in the dispatch stage is increased to 36.4 MW through balancing the cost and benefit associated with higher transfer capacity. The additional transfer capacity allows the low-cost generator G6 in Node 2 to stay online. In addition, the wind generation can be fully absorbed in the scheduling stage, leading to a significant cost reduction. However, it is worth to point out that the fully optimized DLR case increases the amount of the reserve holding and the expected demand shedding in order to better utilize the low-cost resources in Node 2. Compared with SLR where the wind penetration is limited to 38%, DLR allows the wind penetration to reach above 46%.

TABLE III COSTS AND OPERATION PARAMETERS FOR DIFFERENT CASES

Approach		SLR	Real-time only DLR	Fully-optimized DLR
Dispatch Decision	Dispatch Cost [£/30mins]	2018	2018	1661
	Line power flow [MW]	26	26	36.4
	Reserve holding [MW]	26	26	32.4
	Wind curtailment [MW]	9	9	0.6
Real-time operation	Expected re-dispatch cost [£/30mins]	9	-158	41
	Expected demand shedding cost [£/30mins]	4	4	10
	Expected line power flow [MW]	25.7	32.4	36
	Expected wind curtailment [MW]	9	3	3
	Total Cost [£/30mins]	2031	1865	1716

### B. Reserve Sharing among Multiple Sources of Uncertainty

Previous work [17] investigates the optimal utilization of DLR under uncertainty, but only considers the forecasting error associated with DLR. The paper concludes that significant amount of reserve services are required to accommodate the forecasting error of DLR. However, there are multiple sources of uncertainty existing in the power system. They can in fact share some of reserve services and hence reduce the need of extra reserve services driven by each individual source of uncertainty.

By comparing the reserve levels under SLR and DLR in Table IV, it is clear that 26 MW of extra reserve needs to be held if DLR is the only source of uncertainty, while if both

forecasting errors of DLR and wind are considered, only 6.4 MW of extra reserve is needed. Similar conclusion can be drawn that with the optimal application of DLR, the reserve services driven by wind forecasting error itself reduces.

TABLE IV RESERVE HOLDING LEVELS

	SLR	DLR
With Wind Forecasting Error (MW)	26	32.4
Without Wind Forecasting Error (MW)	0	26

However, the reserve sharing effect between wind farm and DLR also depends on the locations of the sources of uncertainty. If the wind farm is located in the “importing” area, as opposed to the above case where the wind farm is located in the “exporting” area, the reserve sharing effect between DLR and wind farm is negligible.

### C. Correlation between Forecasting Errors

In the previous analysis, the forecasting errors of wind generation and DLR are assumed to be independent. However, the positive correlation between DLR and near-by wind farm production has already been observed [20]. To demonstrate the impact, the correlation between forecasting errors of wind generation and DLR is assumed to be “1”. According to the results in TABLE V, positive correlation increases the benefit of DLR by 16%. This is due to the fact that the realization of higher wind availability in exporting area can be accommodated by the realization of higher line capacity from DLR when the correlation is positive.

TABLE V IMPACT OF CORRELATION ON THE BENEFITS OF DLR

	Positively correlated	Independent
Benefits [£/30mins]	367	315

## V. IEEE 24-BUS RTS SYSTEM

To further understand the benefits of DLR, the proposed optimization framework is applied on a modified 24-bus IEEE RTS system, as shown in Fig.3. The specifications of generators, branches and demand can be found in [21]. Fuel costs of generation technologies are 7, 50, 125 and 8 £/MWh for nuclear, coal, oil and hydro, respectively. The reserve utilization costs are assumed to be same as fuel costs. The value of lost load is 30 k£/MWh. To increase the need for extra transmission capability of the North-South boundary, the demand levels in node 1-3 are doubled and 200/500 MW of nuclear plants are added in node 22/23. Generators in node 18 and node 21 are replaced by 2600MW wind farm. Additional 1000MW wind farm is placed in node 16. Two lines, marked with red colour in Fig.3, are equipped with DLR devices. The SLR of the lines are 350MW. The forecasting errors of wind generation and DLR remain the same as in the 2-busbar system. In this case, by combining 9 scenarios for each of two lines with DLR, 9 scenarios for wind generation and 38 potential line outages, there are 27702 scenarios in total. The proposed filter is hence applied to accelerate the calculation.

### A. Impact of Operation Strategies on the Benefit of DLR

Alternative operation strategies have been proposed for DLR. This section compares the benefits of DLR under three different strategies, the results of which can be used as a guideline for the optimal implementation of DLR. In the base case that SLR is applied, the operation cost is 42.3 k£ and 525 MWh of wind generation is curtailed.

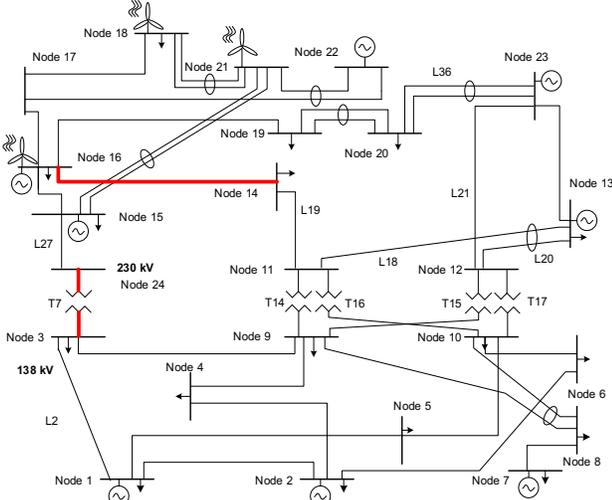


Fig. 3. Modified IEEE 24-Node RTS Topology

For the application of DLR, the simplest way is to implement it only during the real-time operation stage when the actual ratings of the lines become available. In this case, SLR is used in the dispatch stage and re-dispatch actions are activated in the real-time stage to make use of the extra transfer capability. In this case, the cost reduces to 35.1 k£ and only 387 MWh of wind generation are curtailed.

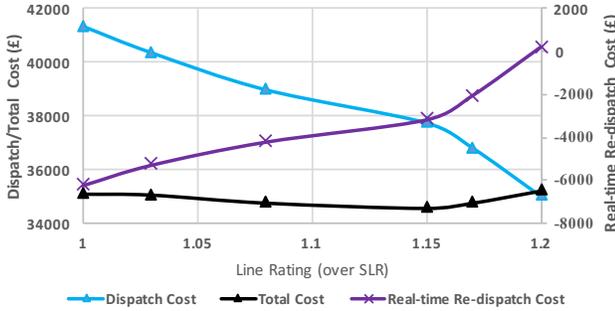


Fig. 4. Operation cost under different quantiles of DLR

Furthermore, previous study in [24] has been carried out to select the single “optimal” quantile of DLR forecast to be used in the dispatch stage under a deterministic fashion. As shown in Fig.4, when higher line rating is used in the dispatch stage, the system dispatch cost reduces due to the increased transfer capability, while the real-time re-dispatch cost would increase in order to deal with the forecasting error in the real-time operation. Therefore, the optimal balance between these two costs leads to the maximum benefit of DLR. In the given case, 1.15 over SLR is the optimal selection with the total operation cost at 34.5 k£ and wind curtailment at 428 MWh.

Instead of pre-selecting a single rating, it is possible to explicitly optimize the application of DLR by using the probabilistic forecasts of DLR in the proposed two-stage stochastic dispatch model. In this way, the benefits of higher utilization of line capacity can be explicitly balanced against the costs of increased holding and utilization of reserve services. The fully-optimized case leads to the lowest operation cost at 32.3 k£ and wind curtailment at 316 MWh.

The results clearly demonstrate that the optimal application of DLR can not only save the system operation cost but also reduce the wind curtailment to achieve higher penetration of

wind generation in the existing network. However, it is worth noting that considering the multiple sources of uncertainty significantly increases the computational burden. For the case that SLR is applied, the computational time is 65s. For the fully-optimized case without filter, it takes more than 3 hours to solve the full problem and hence is not applicable in the large-scale system. By applying the proposed filter with multi-threading parallel processing, the optimization is finished in 497s with 0.5% tolerance.

### B. Coordination with FACTs Devices

In addition to DLR, there are multiple flexible network technologies. There is lack of understanding on how DLR can be optimally coordinated with other flexible technologies and whether they would compete or facilitate with each other. FACTs devices are one of the most efficient and reliable solution to increase the flexibility of the network. In this section, we demonstrate the potential synergy between DLR and FACTs devices.

Two series compensation devices with  $\pm 0.4$  degree of compensation capability are installed at line 2 and line 18. The results in Fig.5 show that the benefit of DLR (cost difference between DLR and SLR) can be potentially increased by 30% through the optimal coordination with FACTs devices. Moreover, the result suggests that the extra benefits from coordinating with FACTs devices is mainly from reducing the cost to deal with the DLR forecasting error.

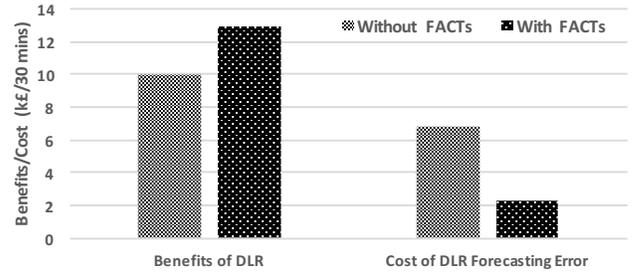


Fig. 5. Benefit of DLR with/without FACTs

### C. Impact of Installed Capacity of Wind Generation

This section analyses the impact of different levels of installed wind generation on the benefit of DLR. The results in Fig. 6 clearly show that a higher installed capacity of wind generation leads to higher benefit of DLR. This is driven by the increased need to transfer the low cost wind generation through the North-South boundary. However, the results also demonstrate that after a certain level of installed capacity, the benefit of DLR tends to saturate, implying the need for extra transmission capability through alternative measures.

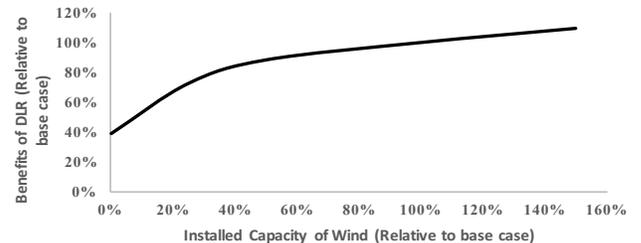


Fig. 6. Impact of installed wind capacity on the benefits of DLR

## VI. CONCLUSIONS AND FUTURE WORK

This paper investigates the benefits of the optimal implementation of DLR in the system with high penetration of wind generation under multiple sources of uncertainty. To do so, probabilistic forecasts for DLR are considered, combining with a two-stage stochastic optimization model that co-optimizes the energy production and reserve holding levels in the scheduling stage as well as the re-dispatch actions in the real-time operation stage. Therefore, DLR can be optimally utilized by balancing the benefits of higher utilization of line capacity against the costs of increased holding and utilization of reserve services due to the forecasting error of DLR. Several case studies show that the proposed stochastic framework allows DLR to be optimally utilized, leading to significant operation cost savings and wind curtailment reduction to support the cost-effective integration of wind generation. We also demonstrate that the reserve services can be shared among multiple sources of uncertainty under stochastic dispatch framework, which needs to be recognized in order to avoid the over-estimation of the required reserve services driven by each single source of uncertainty. This paper also identifies the potential synergies between DLR and FACTS devices. The benefits of DLR are shown to increase along with the higher installed capacity of wind generation, but saturate after a certain level of installed capacity.

In the next step, we plan to enhance the modelling framework by explicitly modelling the high-dimensional dependencies among the multiple sources of uncertainty as discussed in [24]. For the long-distance transmission lines, other factors, such as stability constraints and angle limits, may prevent the higher utilization of transfer capability, limiting the benefit of thermal dynamic line rating. We plan to investigate under which conditions and to what extent these factors may potentially affect the utilization of DLR. Furthermore, annual analysis based on European power systems will be carried out with measured system and weather data to further assess the benefits of DLR in supporting high penetration of RES. In particular, the optimal balance between higher utilization of transmission lines and the reduced lifetime need to be investigated. In addition, as there is significant uncertainty associated with the development of renewables, the option value of DLR in supporting cost-effective transition toward low carbon system needs to be investigated.

### References

- [1] G. Strbac, D. Pudjianto, P. Djapic, and S. Gammons, "Understanding the balancing challenge," Dept. Energy Climate Change, Imperial College London, London, U.K., Aug. 2012.
- [2] "The UK renewable energy strategy", Department of Energy & Climate Change, UK Government, 15 July 2009.
- [3] M. W. Davis, "A new thermal rating approach: The real time thermal rating system for strategic overhead conductor transmission lines—Part I: General description and justification of the real time thermal rating system," *IEEE Trans. Power Syst.*, vol.96, no.3, 1977.
- [4] IEEE Standard for Calculating the Current-Temperature Relationship for Bare Overhead Conductors, IEEE Std 738-2012, 2012.
- [5] "Final Report", TWENTIES project, 2013
- [6] C. J. Wallnerstrom, Y. Huang and L. Soder "Impact from Dynamic Line Rating on Wind Power Integration" *IEEE Trans. Smart Grid.* vol. 6, no. 1, pp. 343-350, 2015.
- [7] Tschampion, Michael, Matthias A. Bucher, Andreas Ulbig, and Göran Andersson. "N-1 security assessment incorporating the flexibility offered by dynamic line rating." In PSCC, 2016.
- [8] T. Yip, C. An, G. Lloyd, M. Aten and B. Gerri "Dynamic line rating protection for wind farm connections" Proc. CIGRE/IEEE PES Joint Symp. Integration of Wide-Scale Renewable Resources into the Power Delivery Syst., pp. 1-5, Jul., 2009, IEEE.
- [9] M.Sara, P.Danny, G.Strbac "Strategic Distribution Network Planning with Smart Grid Technologies" *IEEE Trans. Smart Grid.*, 2016.
- [10] K.Kopsidas and A.Kapetanaki "Optimal Demand Response Scheduling with Real Time Thermal Ratings of Overhead Lines for Improved Network Reliability", *IEEE Trans. Power Syst.*, 2016.
- [11] M. Nick, O. Alizadeh-Mousavi, R. Cherkaoui and M. Paolone, "Security Constrained Unit Commitment With Dynamic Thermal Line Rating," in *IEEE Transactions on Power Systems*, vol. 31, no. 3, pp. 2014-2025, May 2016.
- [12] A. Michiorri, et al., "Forecasting for dynamic line rating", *Renewable and Sustainable Energy Reviews*, vol. 52, pp. 1713-1730, Dec 2015.
- [13] J. L. Aznarte and N. Siebert, "Dynamic Line Rating Using Numerical Weather Predictions and Machine Learning: A Case Study," in *IEEE Trans. Power Delivery*, vol. 32, no. 1, pp. 335-343, Feb. 2017
- [14] Ringelband, T., Schäfer, P. & Moser, A. *Electr Eng* (2013) 95: 99. doi:10.1007/s00202-012-0244-8
- [15] X Sun, Peter B. Luh, Kwok W. Cheung; W Guan, "Probabilistic forecasting of dynamic line rating for over-head transmission lines", *IEEE Power and Energy Society General Meeting*, Jul. 2015, pp. 1–5.
- [16] F. Qiu and J. Wang, "Distributionally Robust Congestion Management With Dynamic Line Ratings," in *IEEE Transactions on Power Systems*, vol. 30, no. 4, pp. 2198-2199, July 2015.
- [17] MA. Bucher, G. Andersson, "Robust Corrective Control Measures in Power Systems with Dynamic Line Rating", *IEEE Transactions on Power Systems* 31.3 (2016): 2034
- [18] E. M. Constantinescu, V. M. Zavala, M. Rocklin, S. Lee and M. Anitescu "A computational framework for uncertainty quantification and stochastic optimization in unit commitment with wind power generation" *IEEE Trans. Power Syst.*, vol. 26, no. 1, pp.431-441, 2010.
- [19] N. Meinshausen, "Quantile regression forests," *The Journal of Machine Learning Research*, vol. 7, pp. 983-999, 2006
- [20] Kazerooni, A. K., et al. "Dynamic thermal rating application to facilitate wind energy integration." *PowerTech*, Trondheim. 2011.
- [21] Moreno, R., Pudjianto, D., and Strbac, G., "Transmission Network Investment with Probabilistic Security and Corrective Control", *IEEE Trans. Power Syst.*, Vol 28, No 4, pp 3935-3944, Nov 2013.
- [22] FICO Xpress Optimization Suite. [Online].
- [23] Dupin, Romain, Andrea Michiorri, and Georges Kariniotakis. "Dynamic line rating day-ahead forecasts-cost benefit based selection of the optimal quantile." *CIREN Workshop* 2016
- [24] Wang, Yi, Ning Zhang, Chongqing Kang, Miao Miao, Rui Shi, and Qing Xia. "An efficient approach to power system uncertainty analysis with high-dimensional dependencies." *IEEE Trans. Power Syst.*, 2017

**Fei Teng** (M'15) received his Bachelor degree from Beihang University, China in 2009 and PhD degree from Imperial College London in 2015. He is currently a lecturer in Control and Power Group at Imperial College London. His research interests include power system control and operation, system flexibility and stochastic optimization.

**Romain Dupin** is a graduate of Ecole Centrale Lille, where he followed the option Chair of Electrical Networks, and from the University of Lille 1, where he gained a Master's degree in electrical engineering in 2014. Since September 2014, he has been a PhD student in the MINES ParisTech Center for Processes, Renewable Energies and Energy Systems (PERSEE) in Sophia Antipolis, France. He works on developing methods for forecasting dynamic line rating and studies the impacts of dynamic line rating on power system management.

**Andrea Michiorri** received his Eng. degree in Mechanical Engineering with a specialization in Energy from the University of Rome 'La Sapienza' in 2005. He then obtained a PhD from the University of Durham in 2010 with a dissertation on the thermal state estimation of power system components. He

is currently an associate professor at the MINES-ParisTech Center for Processes, Renewable Energies and Energy Systems (PERSEE) in Sophia Antipolis, France, working on the integration of renewable resources and distributed generators into the power system, with a particular focus on the aspects of decision making under uncertainty.

**George Kariniotakis** (S'95-M'02-SM'11) was born in Athens, Greece. He received his Eng. and M.Sc. degrees from Greece in 1990 and 1992 respectively, and his Ph.D. degree from Ecole des Mines de Paris in 1996. He is currently with the Centre PERSEE of MINES ParisTech as a senior scientist and head of the Renewable Energies and Smartgrids Group. He has authored more than 220 scientific publications in journals and conferences. He has been involved as participant or coordinator in more than 40 R&D projects in the fields of renewable energies and distributed generation. Among them, he was the coordinator of some major EU projects in the field of wind power forecasting and integration such as Anemos, Anemos.plus and SafeWind projects. His scientific interests include among others timeseries forecasting, decision making under uncertainty, modelling, management and planning of power systems.

**Yanfei Chen** received the B.S. degree in electrical engineering from Northumbria University UK in 2011, the M.S. degree in electrical engineering from Imperial College London UK in 2012, and Ph.D. degree from Imperial College London UK in 2017. He is currently a market risk manager at Lloyds Banking Group. His research interests include demand power system operation, FACTS devices and wind energy.

**Goran Strbac** (M'95) is a Professor of Electrical Energy Systems with Imperial College London. His research interests are in modelling and optimization of electricity system operation and investment, economic and pricing, and integration of new forms of generation and demand technologies.



**Annexe 3 - R. Dupin, A. Michiorri, G. Kariniotakis, 'Optimal Dynamic Line Rating Forecasts Selection Based on Ampacity Probabilistic Forecasting and Network Operators' Risk Aversion', Submitted for publication at IEEE Transactions on Power Systems, Under review.**

---



# Optimal Dynamic Line Rating Forecasts Selection Based on Ampacity Probabilistic Forecasting and Network Operators' Risk Aversion

Romain Dupin, Andrea Michiorri, *Member, IEEE*, and George Kariniotakis, *Senior Member, IEEE*

**Abstract--** Real-time current-carrying capacity of overhead conductors is extremely variable due to its dependence on weather conditions, resulting in the use of traditionally conservative static ratings. This paper proposes a methodology for exploiting the latent current-carrying capacity of overhead transmission lines taking into account line ampacity forecasts, power flow simulations and the network operator's risk aversion.

The procedure can be described as follows: Firstly, probabilistic forecasts for the current rating of transmission lines are generated, paying particular attention to the reliability of the lower part of the distribution. Secondly, a cost benefit analysis is carried out by solving a bilevel stochastic problem that takes into account the reduction in generation costs resulting from a higher power transfer capacity and the increased use of reserves caused by forecast errors. The risk appetite of the network operator is considered in order to accept or penalize high-risk situations, depending on whether the network operator can be described as risk neutral or risk averse.

**Index Terms--** Dynamic Line Rating, Numerical Weather Predictions, Probabilistic Forecasts, Risk Management

## I. INTRODUCTION

CURRENTLY, power system operators face several challenges, due to increased peak demand, electricity market deregulation and increasing penetration of renewable energy sources. Due to these latter factors, grid sections are often operated closer to their voltage or current limits. From a network operator's point of view, network reinforcement is often the default option for alleviating these problems. However, this is a capital-intensive option and, in this context, the alternative solution of the Dynamic Line Rating (DLR) is gaining popularity.

DLR technology centres on the fact that the current-carrying capacity of overhead conductors is limited by thermal constraints, in addition to voltage drops and stability limits. When the operating temperature rises, the conductors elongate, approaching the ground or other objects. When the clearance distance between the line and the objects below is too short this can lead to potentially dangerous situations. In order to limit disastrous consequences, a minimum clearance is determined

by national or grid regulations, including the definition of a maximum temperature for the core of the line. Conductor temperature is in turn dependent on the heat balance established between the heat dissipated by the Joule effect within the conductor, and the heat exchange with the environment on its external surface. This heat exchange is strongly influenced by wind speed, air temperature and solar radiation, parameters that can vary considerably in the space of one day or even one hour. The link between the line temperature and weather parameters, which is described in detail in [1], [2], is used to set a current rating in line with regulations.

Traditionally, the parameters used to define the line rating are set as static. The current rating obtained is called Static Line Rating (SLR), which is usually defined so that it remains below the real-line rating up to 99% of the time [3] for the duration of a season. Based on this definition, a significant margin of improvement exists between SLR and the real value of the line rating, depending on weather characteristics. In this context, it was initially proposed in [4] to set the line rating according to dynamic measures of weather parameters, the new rating being qualified as the DLR.

The use of DLR instead of SLR for network operations presents multiple benefits and has already been studied in the literature. For example, [5] and [6] show the potential impact of DLR on the economic dispatch, [7] shows how DLR can contribute to increasing renewable energy penetration without grid reinforcement, and [8] demonstrates how grid reliability can be improved with DLR. These aspects could be taken into account during planning operations, in which case DLR forecasts would be required.

The majority of applications proposed in the literature feature the generation of probabilistic DLR forecasts. Most of the time, based on these forecasts, a conservative choice of an ampacity value is made for use in planning operations, and quantile forecasts with a fixed nominal proportion  $\tau$  are regularly employed [9]. Forecasts  $\overline{DLR}_{t+h|t}^\tau$  made at an instant  $t$  for an instant  $t+h$  are then set to ensure the probability of being higher than the future observation  $DLR_{t+h}$  equal to  $\tau$ :

$$P(\overline{DLR}_{t+h|t}^\tau > DLR_{t+h}) = \tau \quad (1)$$

---

Part of this work was carried out thanks to an exchange mobility grant awarded to the first author from the project ELECTRA IRP (Grant No 609687), funded in part by the European Commission under the 7th Framework Programme.

R. Dupin, A. Michiorri and G. Kariniotakis are with MINES ParisTech, PSL Research University, PERSEE - Centre for processes, renewable energies and

energy systems, CS 10207, 1 rue Claude Daunesse 06904 SophiaAntipolis Cedex, France.

(e-mails: romain.dupin, andrea.michiorri, georges.kariniotakis each with @mines-paristech.fr).

A state of the art of real applications of this kind in Europe is described in [10]. In [11] and [12], where the experiences of the NETFLEX project are described, probability  $\tau$  is set as equal to 2%. In [13], probability  $\tau$  fixed levels of 1%, 5%, 10% and 20% are tested. In [14], a probability  $\tau$  of 1% is considered. Other studies could also be quoted, such as [15] and [16], where  $\tau$  probabilities of 10% and 2.5% are respectively considered.

Recently, it has been proposed in the literature to no longer set the value of DLR forecasts with a fixed level of frequency, but to use stochastic optimization instead. In [17] and [18], this is done with two-stage stochastic optimization, which aims at minimizing the sum of the generation costs, reserve allocation and potential reserve activation due to DLR forecast errors. A similar approach is also proposed in [19], where instead of reserve activation, it is considered that the retroactions are achieved through voluntary and involuntary load reduction. References [20] and [21] both propose considering that the constraint associated with the line ampacity could be replaced with a cost in the objective function in case of non-respect of the constraint.

The above two approaches are radically different. The one with the fixed quantiles favours a conservative approach independent from opportunities to improve social welfare, while ensuring a low risk level. On the contrary, with the second approach based on stochastic optimization, the authors consider a risk-neutral approach and aim at maximizing the social welfare. In this context, the term ‘‘social welfare’’ refers to the sum of the consumer and producer surpluses. If the load is considered as inelastic towards prices, maximizing the social welfare is equivalent to minimizing the operation costs.

In this paper, we propose to evaluate the benefits of DLR based on an intermediate strategy, which aims at improving social welfare while ensuring low levels of risk, required for application on the field. The key contributions can be summarized as follows:

1) Several alternative strategies for integrating DLR into planning operations are proposed. They aim at improving the economic benefits, (referred to here also as the ‘‘social welfare’’) for a case where electricity consumption is inelastic towards price, while maintaining low values for several parameters to which the Transmission System Operator (TSO) is averse. The evaluation of these strategies allows us to understand the significant benefits of using risk-averse strategies for DLR probabilistic forecasts, compared to traditional approaches that use fixed quantiles or risk-neutral strategies.

2) We propose a test case and a methodology to evaluate the economic value of both DLR forecast models and proposed strategies for using DLR forecasts. This is based on the use of lookup table and allow considering grid characteristics.

3) The proposed study takes into account a high number of realistic DLR probabilistic forecasts, generated with weather station observations and machine learning methods. This is a more complete approach than similar ones proposed in the literature, which generally consider only a single virtual DLR probabilistic forecast.

The paper is structured as follows: first, in section II, the proposed methodology is presented. Section III presents the

case study used for the model evaluation. In section IV the main results are presented, and finally section V presents the conclusions and perspective of this work.

## II. MODELLING APPROACH

The problem to be solved is the optimal operation of a grid on which some lines are equipped with DLR. It is similar to that formulated in [18] and [22], which assess the DLR value in grid management. Since several uncertainties are involved, a stochastic optimisation approach is applied. Below, several problem formulations are proposed for setting the DLR forecasts, according to different objectives set by the TSO.

### A. Risk Neutral Strategy – Vertically Integrated Monopoly

We first consider that the electricity producers and electric system operators are the same actor. The problem addressed here is described in [18] and can be modelled as a two-stage stochastic optimization problem.

For a stochastic optimization problem taking into account DLR forecasts, different terms could be considered in the objective function. One important question concerns the introduction and use of penalties regarding situations in which the current is slightly higher than the thermal limits of the lines, as in [20], [21], [23]. Such cost definitions require knowledge of potential incidents on the grid, their associated probability, and recourse actions when these costs are too high. In this paper, we consider a preventive approach regarding N-1 incidents, and penalties requiring a corrective approach are not introduced. It should be stressed that the simplifications allowed with this preventive approach permits the use of lookup tables which are necessary to provide computations for a high number of observations in a reasonable time.

The objective function is risk neutral, the objective being to minimize production costs of generators in the system plus the costs of reserve allocation and potential activation (2):

$$\min \left\{ \begin{array}{l} \sum_{g=1..Ng} (\pi \text{fuel}_g \cdot P_g + I_g \cdot \pi \text{fix}_g) + \\ \sum_{g=1..Ng} (\pi \text{hup}_g \cdot H_g^{\text{up}} + \pi \text{hdo}_g \cdot H_g^{\text{do}}) + \\ \sum_{s \in N_s} \sum_{g=1..Ng} \rho_s \cdot (\pi \text{rup}_g \cdot R_{g,s}^{\text{up}} + \pi \text{rdo}_g \cdot R_{g,s}^{\text{do}}) \end{array} \right\} \quad (2)$$

where  $Ng$  is a set of conventional generators;  $I_g$  is a binary variable with value 1 describing a committed generator, and 0 if not;  $\pi \text{fuel}_g$  is the fuel cost for generator  $g$  (€/MWh);  $\pi \text{fix}_g$  is the commitment price for a conventional generator  $g$  (€/h);  $P_g$  is the scheduled output of generator  $g$  (MW);  $\pi \text{hup}_g$  and  $\pi \text{hdo}_g$  are the costs for maintaining up and down reserve for a generator  $g$  (€/MWh);  $H_g^{\text{up}}$  and  $H_g^{\text{do}}$  are the up and down reserve service holding amounts for generator  $g$  (MW);  $N_s$  is the set of potential future realizations of DLR and other stochastic variable observations, with each scenario having a probability  $\rho_s$  of occurrence set with probabilistic forecasts;  $\pi \text{rup}_g$  and  $\pi \text{rdo}_g$  are the reserve activation costs (€/MWh); and  $R_{g,s}^{\text{up}}$  and  $R_{g,s}^{\text{do}}$  are the activated reserves from a generator  $g$  at scenario  $s$  (MW).

The constraints are those of a DC power flow, and are described in [18] and [22]. Here, N-1 constraints are added to

account for the risks of line failure, as proposed in [24], which investigates DLR use for transfer capacity setting.

### B. Risk-Neutral Strategy – Separate Grid Operators and Electricity Producers

In the previous strategy, the generation planning is affected by the potential recourse actions set by the TSO. It is however unlikely that electricity producers would modify their day-ahead decisions according to the risks and potential costs of DLR forecast errors, which are assumed by the TSO.

In order to decouple the decision of the generator-planned production levels from the decision of the DLR forecast value, a bilevel stochastic optimization problem is used here, with a leader problem (3)-(4) and a follower problem (5):

$$\min_{x \in X, y \in Y} F(x, y) \quad (3)$$

s. t.

$$G_i(x, y) \leq 0 \text{ for } i \in \{1, 2, \dots, I\} \quad (4)$$

$$y \in \arg \min_{z \in Y} \{f(x, z): g_j(x, z) \leq 0, j \in \{1, 2, \dots, J\}\} \quad (5)$$

For a risk-neutral approach, the upper-level objective function  $F$  is the same as that described in (2), and the constraints  $G_i$  are those described in the previous section.

The lower-level objective function  $f$  is the objective function defined according to the goals of the electricity producers. Considering no uncertainties except those for which the TSO is responsible and which in this case are only the DLR forecast errors, this can be written as (6):

$$f(x, z) = \left\{ \sum_{g=1..N_g} (\pi \text{fuel}_g \cdot P_g + I_g \cdot \pi \text{fix}_g) \right\} \quad (6)$$

In a future work, reserve activation and allocation terms could be added in (6), provided that other uncertain variables such as renewable energy levels of production are added, for which the producers assume the forecast error risks. The constraints  $g_j$  are the same as those of the leader problem, minus the constraints associated with the values of reserve allocations and activations. The upper-level decision vector includes the values of allocated reserves, activated reserves and DLR forecasts. The lower-level decision vector includes the planned production levels and the list of activated generators. Only the DLR forecast value, set with the leader problem, has an impact on the constraints of the follower problem.

### C. Risk Averse Strategy

In the previous section, the objective function (2) was defined such that the TSO was considered risk neutral in terms of reserve activation risks. Here, we propose to modify this problem by introducing a risk appetite function  $v_\beta(x)$ , to take into account TSOs' risk aversion:

$$\min \left\{ \begin{array}{l} \sum_{g=1..N_g} (\pi \text{fuel}_g \cdot P_g + I_g \cdot \pi \text{fix}_g) + \\ \sum_{g=1..N_g} (\pi \text{hup}_g \cdot H_g^{\text{up}} + \pi \text{hdo}_g \cdot H_g^{\text{do}}) + \\ v_\beta \left( \sum_{s \in N_s} \sum_{g=1..N_g} \rho_s \cdot (\pi \text{rup}_g \cdot R_{g,s}^{\text{up}} + \pi \text{rdo}_g \cdot R_{g,s}^{\text{do}}) \right) \end{array} \right\} \quad (7)$$

It should be stressed that the risk aversion towards risk activation costs defined here is a trade-off solution: risk aversion towards other parameters, such as load shedding, would be more representative of TSOs' behaviour. However, it would make the problem more complex, and impossible to compute for a very high number of scenarios and forecasts, as it is the case here. By considering these reserve costs as similar to risk indices, it is thus possible to evaluate first different risk aversion functions, and also determine the economic value of DLR forecast models in a latter approach.

The shape of the function  $v_\beta$  is arbitrarily set by the TSO, depending on its objectives. Here, three functions are proposed inspired from [20], [21], where virtual costs associated with line ampacity violations by currents are defined:

- A linear function:

$$v_\beta(x) = (1 + \beta) \cdot x \quad \beta \geq 0 \quad (8)$$

- A quadratic function:

$$v_\beta(x) = x + \beta \cdot x^2 \quad \beta \geq 0 \quad (9)$$

- An exponential function:

$$v_\beta(x) = \begin{cases} x & \text{if } \beta = 0 \\ \frac{e^{\beta \cdot x} - 1}{e^\beta - 1} & \text{if } \beta > 0 \end{cases} \quad (10)$$

The parameter  $\beta$  aims at describing the TSO's aversion to the risk of observing a DLR forecast error with a high cost. When  $\beta$  is set equal to 0, the TSO exhibits risk-neutral behaviour.

### D. Simulation Approach

The solution of the problem described above represents a significant computational challenge due to the high number of constraints generated by the stochastic nature of the problem, the respect of the N-1 criterion, and the presence of discrete values related to the activation of generators. This paper aims at carrying out a prospective analysis of the benefits of different DLR forecast strategies over a long period of time and considering a high number of different parameters, here the values of  $\beta$  and the nature of the penalty functions.

This requires solving a high number of stochastic problems. As an example, considering 100 values of  $\beta$ , 45000 forecasts and three different penalty functions, 13.5 million simulations would be required. It is therefore necessary to reduce the computational time taken to resolve the optimisation problems.

To do so, the problem is simplified considering the following hypotheses and properties:

- Since the DLR forecast may remain relatively close to the SLR, and that up and down reserves must be allocated in case of any forecast error scenarios, it is unlikely that DLR would have a significant impact on the list of activated generators. The list of activated generators  $I_g$  is thus defined considering that all DLR values are equal to the SLR.
- For the case presented in this paper, only line failures and DLR forecast uncertainties are considered. Uncertainties related to renewable energy sources and electric demand are not considered. Recourse actions involving activating reserves can only be carried out for inaccurate DLR forecasts, while other potential incidents (which may face a similar preventive approach) are outside the scope of this work.

For a test case such as the one described in [18], the property of reversibility could be considered regarding the states of generator production towards DLR values, where all conventional generators participate in recourse actions, and the reserve activation costs are proportional to the day-ahead prices. With the properties described above, the problem can be resolved by solving different Security Constrained Optimal Power Flows (SCOPF) according to the following steps:

- 1) A first SCOPF is resolved to initialize the problem, where the line ratings are set at the value that corresponds to the SLR, to define the list of the activated generators  $I_g$ .
- 2) After setting  $I_g$ , a SCOPF is computed for each possible value of line rating  $\Delta_1$ .
- 3) For each forecast  $\Delta_1$ , the values of allocated reserves  $H_g^{up}/H_g^{do}$  are set by: a) running a SCOPF with a line rating set as  $\Delta_1$ , b) calculating the difference between generator outputs in this situation and generator outputs after the SCOPF in step 1. This method implies that the problem associated with the SCOPF is strictly convex, which may not be the case with a linear approach. In the study proposed here, a negligible quadratic component is added to the generator cost function, in order to ensure strict convexity.

- 4) For a scenario  $s$  associated with a DLR realization  $\Delta_{1,s}$ , if  $\Delta_{1,s}$  is lower than inferior to the DLR forecasted value  $\Delta_1$  selected by the TSO, the activated reserves are found by computing the differences in the outputs of the different generators associated with the solutions of the SCOPFs made with the line ratings equal to  $\Delta_{1,s}$  and  $\Delta_1$ .
- 5) Then, considering the levels of probability  $\rho_s$  of a DLR observation  $\Delta_{1,s}$ , it is possible to select an optimal value for the DLR forecast  $\Delta_1$ .

By considering a limited set of possible states of load L1 and L2 (in this work, 20 for each load area, going from 0% of the nominal load to 100%), DLR planned forecasts (100, going from 100% of the SLR to 200%) and DLR potential observations (100, going from 100% of the SLR to 200%), it is possible to compute the different SCOPFs for each state in which DLR improvements bring benefits. Thus, lookup tables can be built (Fig. 1), each value of the table being associated to a tuple of scenario, and the use of this tool allows reducing considerably the computation time for a period associated to a high number of observations (Fig. 2).

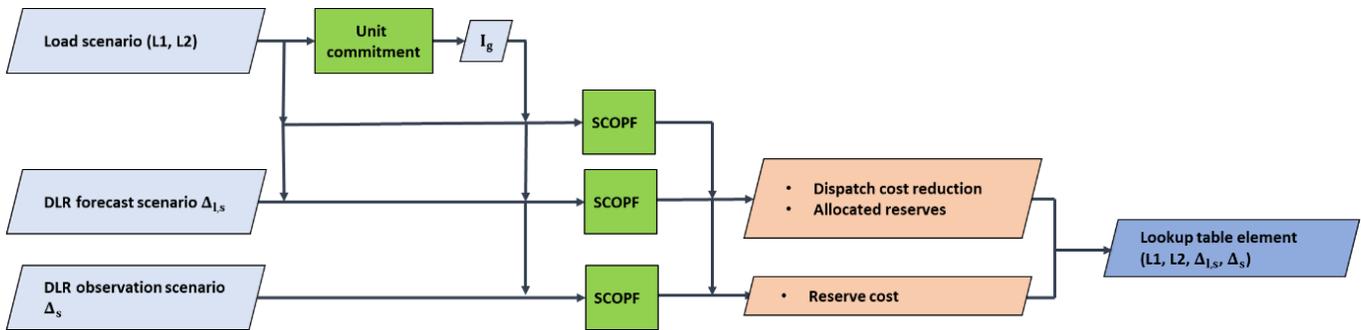


Fig. 1. For a load scenario (L1, L2), a DLR forecast  $\Delta_1$  and a DLR observation  $\Delta_{1,s}$ , computation process for setting the associated value in the lookup table.

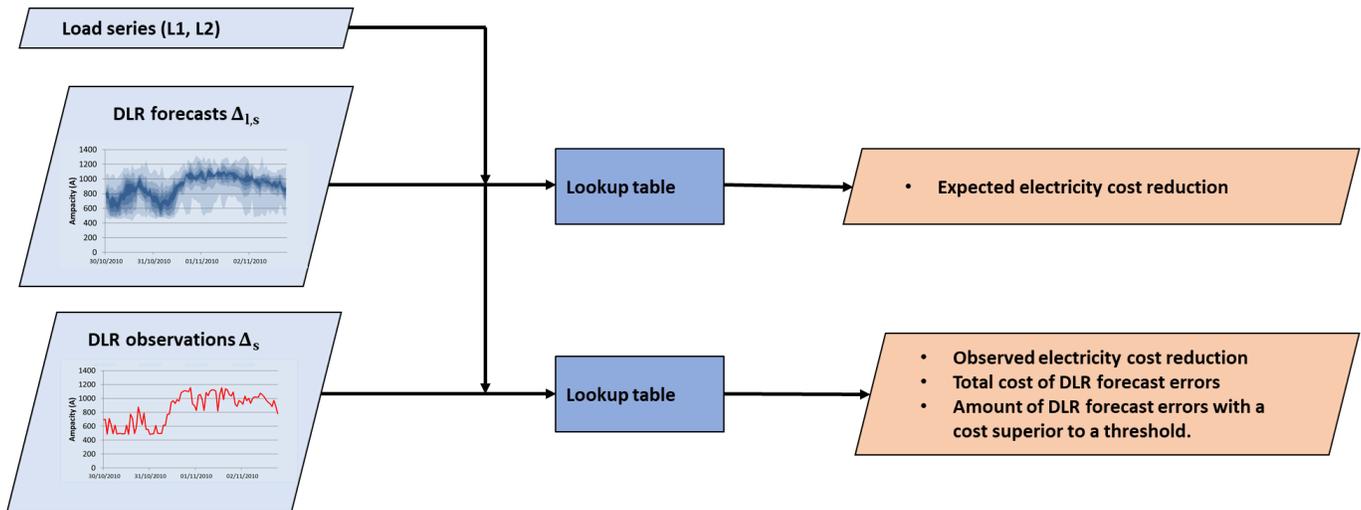


Fig. 2. Flowchart associated to the computations made with the lookup tables.

### E. DLR Forecast Generation

Here we use the same weather station data as in [15]. For a line located in the UK, several weather stations have been installed all along the line for DLR use. In this study we consider 6 of them. For each station, weather characteristics were measured every 5 minutes for the period 2009-2010. Using Numerical Weather Predictions (NWP) provided by the European Centre for Medium-Range Weather Forecasts (ECMWF), day-ahead probabilistic forecasts are generated using a machine learning method.

The available data set is split into training and testing sets. For this study, these sets are generated with sliding windows, the models are updated every month, and the training sets used correspond to observations associated with the whole year preceding the moment of the model update.

The models are trained to provide forecasts every day at 12:00 for horizons going from 24 hours to 47 hours. The following inputs are used to generate the forecasts:

- The DLR observation at the instant  $t$  the forecast is made.
- The mean value of the DLR observations made at the instants  $t+h-48$  hours,  $t+h-72$  hours and  $t+h-96$  hours.
- NWPs for the zonal and meridional wind speeds at 10m (U and V), the surface solar radiation downwards (S) and the ambient temperature at 2m (T) for the four positions that frame the location of the weather station. The spatial resolution of the considered NWPs is  $0.125^\circ$ . Since the ECMWF forecasts are only made for 3-hour time steps and DLR forecasts are requested with hourly resolution, linear interpolation is applied to obtain hourly values.
- Four DLR forecasts associated with the ECMWF forecasts are provided at the instant where the forecasts are made for the considered horizon. For a given position, the DLR forecast is provided with the CIGRE physical model [1] using the forecast values of U, V, S and T.

No selection of the transmission lines' critical span is made here. Thus, the data from each weather station are studied in the same way as if each station were set at the position of the critical span as proposed in [15] in order to increase the amount of observations used.

Regarding the used machine learning method, a Quantile Regression Forest model (QRF) is selected [25]. This model is the same as the one used in [15] for DLR forecasting. This machine learning method is an ensemble method, based on the generation of  $k$  decisional trees, each one trained with a randomly selected subset of features and of data. For the forecast generation, the outputs of all the trees are concatenated and sorted, and the quantile forecasts are drawn from the sorted list (Fig. 3).

The choice of such a machine learning method could be discussed. Regarding the latest competition associated to the use of machine learning in energy fields, the Global Energy Forecasting Competition [26], the methods using bootstrap aggregating processes (bagging) as the QRF appear as being less effective than the ensemble methods associated to boosting, as the XGBoost model [27]. Compared to such methods, the

QRF tends to generate bias errors, the model being less effective at explaining complex relationships, and even if such methods have not been used yet to provide DLR forecasts, a XGBoost model or a Light Gradient Boosting Machine model [28] could be preferred. However, for this case study, the differences between the two models would be little, due to the little amount of features being used. Moreover, a QRF is easy to configure, the model outputs converging when the number of decisional trees becomes high, and a single QRF directly provides all the quantile forecasts. On the contrary, with gradient boosting methods, a different model should be trained for each quantile, and methods as Bayesian optimization [29] and cross validation should be used for each model in order to avoid errors due to a non-optimal configuration, thus making the training of the model much longer. To give an order of magnitude, instead of a single QRF with the bagging method, 999 models would be required considering boosting, in addition to a high number of models being trained for each one to provide optimal parameters. Due to these reasons, the QRF is here preferred to gradient boosting methods.

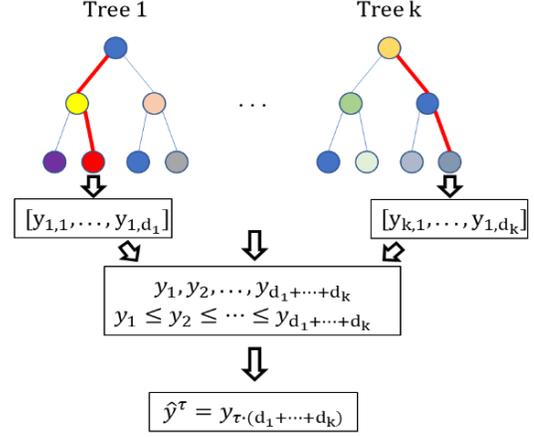


Fig. 3. Illustration of the process of a quantile forecast generation with a QRF method.

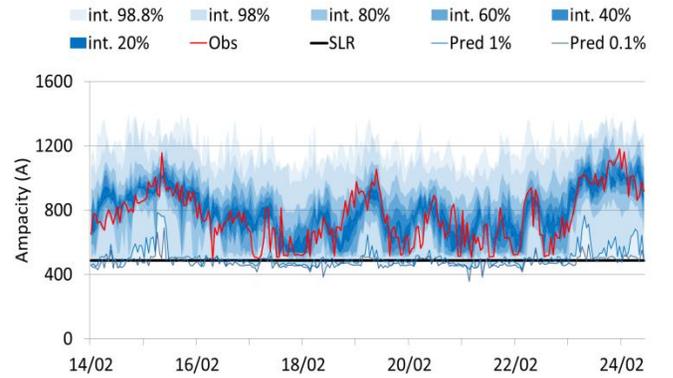


Fig. 4. Example of day-ahead DLR probabilistic forecasts for station 1, the different probability intervals (int.) being shown. The 0.1% and 1% quantile forecasts (Pred.) are the lower limits of the 99.8% and 98% probability intervals.

This model is set up with 2000 trees, each of which is trained with 5 randomly selected features and with a maximal leaf size

set as equal to 5. In most of the studies associated with DLR forecasts, the forecasts are used with fixed quantiles varying from 1% to 10%, which thus requires using the forecast model to provide percentile forecasts. However, here, these forecasts are used as inputs of risk-averse strategies, which aim at providing results that are similar to 1%-quantile DLR forecasts in terms of risks. For this reason, the model provides a set of 999 quantile forecasts, for quantiles ranging from 0.1% to 99.9% in 0.1% steps. An example of such forecasts is shown in Fig. 4.

The Mean Absolute Percentage Error (MAPE) and reliability criteria are considered here to evaluate the performance of the forecast models with regard to state-of-the-art models. First, regarding the MAPE, a comparison can be made with the persistence model, i.e. a model where a forecast is set as equal to the observations made at the moment of the forecast.

For this case, the MAPE for the QRF and the persistence model are equal to 11.1% and 16.1% respectively. The relative difference of 31% is in line with the results found in [15].

In terms of reliability, the frequency of overestimation for quantiles 0.1%, 1% and 2% is equal to 0.8%, 1.8% and 2.7% respectively. With binomial laws, considering perfectly reliable forecasts and the number of considered forecasts, it is easy to find that such frequencies should respectively be inferior to 0.14%, 1.11% and 2.16% with a level of probability of 99%. The proposed forecast model is then not reliable, even if the last two frequencies are in line with the results found in [14] and [30].

Despite this weakness, this model is considered as acceptable. The first reason is based on recent research made on DLR forecasts, which indicate that the performances of the model are close to the models currently used by the TSOs. Secondly, the reliability criterion is here used to evaluate the model, but there is no evidence in the literature that this parameter is the most important one regarding DLR forecasts, and other criteria as the sharpness might be more important. As an example, with the traditional use of a fixed quantile, it might be considered that a TSO might prefer to use 1% quantile forecasts from a non-reliable but sharp forecast model than 2% quantile forecasts from another model, more reliable but less sharp. Such questions are still not answered, and they are to be addressed by using simultaneously DLR forecasts with different statistical properties and economic models providing an evaluation of the value of the forecasts. In future work, the development of the tool presented in this paper based on the use of lookup tables aims at realizing such a research of the required properties of DLR forecast models.

### III. CASE STUDY

#### A. Network Description

The IEEE 24-bus grid is considered here (Fig. 5), with the same characteristics as the ones in [31]. It is split into two areas, each of which is considered with different load values.

The reserve allocation and activation costs are set similarly to [18]: the costs for up and down reserve allocation,  $\pi_{\text{hup}_g}$  and  $\pi_{\text{hdo}_g}$ , are set as equal to 6 €/MWh for every generator  $g$ ; the reserve activation costs are set as equal to the fuel price for the down-reserve activation, and as equal to 150% of the fuel price

for the up-reserve activation.

The computations of DC optimal power flows are carried out using PyPower [32], and the security constraints are added by generating constraints obtained with Benders cuts. It is considered that no line failures could occur on line 8-7, this part of the grid being operated in a radial configuration.

Lines 8-9 and 8-10 are considered to be equipped with DLR functionality, and to have exactly the same DLR value at each time. These two lines are indeed connected from bus 8 to buses 9 and 10, the latter two being at the same position. The reason for choosing these two lines is the fact that they appear to be congested when computing the Total Transfer Capacity from area 1 to area 2.

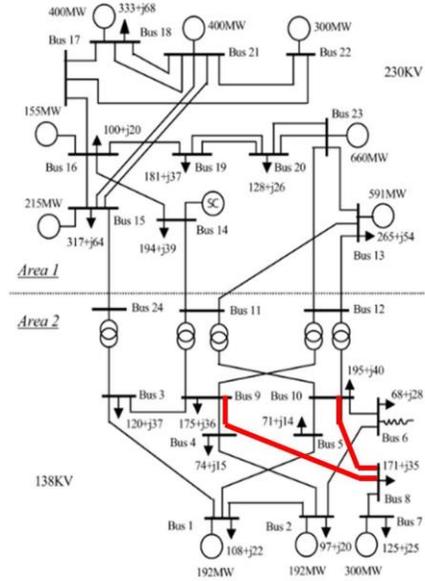


Fig. 5. IEEE 24-bus reliability test system. The lines equipped with DLR are marked in red.

Lines 8-9 and 8-10 are considered to be equipped with DLR functionality, and to have exactly the same DLR value at each time. These two lines are indeed connected from bus 8 to buses 9 and 10, the latter two being at the same position. The reason for choosing these two lines is the fact that they appear to be congested when computing the Total Transfer Capacity from area 1 to area 2.

The line dynamic ampacity is set as equal to its initial value provided in the grid data, multiplied by the DLR divided by the SLR value. For this study, it cannot be below its nominal value. Three SLR values are used, one for each season, and are set such as to below the observed DLR for 99% of the time for the year 2009. The seasons are defined as winter (December to February), spring/autumn (March to May and September to November) and summer (June to August). Different values of SLR are defined for each weather station.

#### B. Load Series

In most studies involving grid simulations using DLR forecasts, only a given configuration of the grid is used. However, the grid configuration has a significant impact on the DLR impact and the selection of the optimal forecast.

We therefore propose generating load time series with a bootstrap process, considering only congestion situations, and

taking the frequencies of the different situations from a study of historical time series. ENTSO-E data for the year 2010 are exploited for this goal. Historical data from France (area 1) and Germany (area 2) are used, since these data feature a high variety of congestion issues for the bootstrap process.

#### IV. RESULTS

In order to evaluate the value of the different strategies, the cost reductions from the initial total system costs,  $L_{SLR}$  (€), to the final total system costs obtained when DLR forecasts are used,  $L_{DLR}$  (€), are considered as benefits. They are normalized by dividing them by the total  $L_{SLR}$  costs associated with the situations where SLR is used:

$$\text{Benefits} = 100\% \cdot \frac{L_{SLR} - L_{DLR}}{L_{SLR}} \quad (11)$$

In addition to the benefits, financial losses and risks are also evaluated, using three indices:

- 1) The frequency of events requiring reserve activations due to overestimations of DLR forecasts (%).
- 2) The total cost of reserve activation  $C_{res\ act}$  (€) for the studied period. As with the benefits, this cost is normalized using the total costs of the system when the SLR is used:

$$C_{res\ act, n} = 100\% \cdot \frac{C_{res\ act}}{L_{SLR}} \quad (12)$$

- 3) The frequency of errors with a cost above a defined threshold  $f\_reserve(\text{threshold})$  (%). The idea behind this is to address the fact that TSOs may aim at maintaining the DLR error magnitude below a certain threshold most of the time. This is especially the case when the reserve may be hard to call, which could be considered as when it is costly. The threshold is arbitrarily defined equal as to €1500. Situations involving such events are qualified as incidents.

##### A. Traditional Strategies

A first study is made by considering traditional methods, i.e. the use of fixed quantiles and risk-neutral strategies. Three strategies are tested:

- 1) Low arbitrary quantile  $\tau$  of 1% is selected.
- 2) High arbitrary quantile  $\tau$  of 20% is selected.
- 3) The value of the DLR forecast is dynamically set to minimize the expected operational costs, with a risk-neutral strategy.

Regarding the choice of the quantile of 20%, it is to stress that when the selected quantile becomes superior to 20%, the benefits converge toward a value of 0.97%. This is shown on Figure 3, where the evolution of the observed benefits with the value of a fixed selected quantile is represented.

The results shown on Figure 3 are to be compared to [33], where a similar figure is provided. Contrary to the Figure 3, [33] shows that benefits do not converge but drop sharply when quantiles reach values superior to 20%. This difference in behaviour between the results presented here and [33] is due to the fact that the grid characteristics are considered in our study, and that when DLR forecast values increase above a given threshold no further improvements are observed on the grid, either because the congestions have been erased or because

other congestions have appeared. These other congestions could be new congestions on other lines or changes in congestion natures from thermal limitations to stability or voltage drop limitations [34].

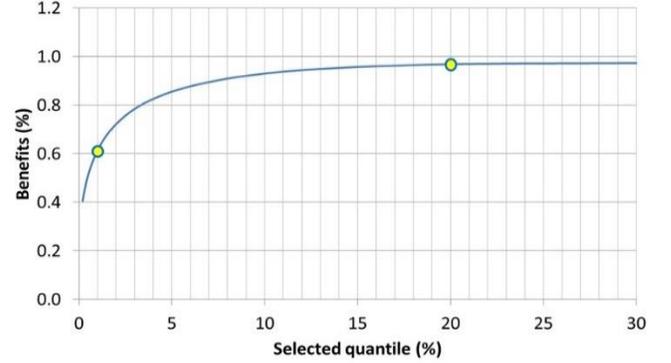


Fig. 6. Evolution of the benefits as a function of the values of the selected fixed quantiles. The two yellow circles are associated to the use of fixed quantiles equal to 1% and 20%.

The observed benefits are computed for the studied period and shown on Table I, with the associated risk and loss indices associated being also shown.

The expected benefits, which are equal to the average of the expected benefits for the whole set of resolved optimization problems, were also computed, and for every situation considered in this paper, we found that the relative difference between the expected and observed benefits was less than 2%. This is not surprising, considering the high amount of observations used and the fact that the stochastic part of the benefits, which is the total costs of the activated reserves, is lower than 10% and 3% of the total benefit, respectively with the use of risk-neutral optimization and a 1% quantile DLR forecast. We can thus consider that the expected and observed benefits are equal. This allows us to compare forecast models and DLR forecast setting strategies by setting the same levels of observed benefits, which are considered as known because equal to the expected benefits.

TABLE I  
STRATEGY COMPARISON: OBSERVED BENEFITS, FREQUENCY OF ERRORS AND FREQUENCY OF INCIDENTS.

Strategy used	Benefit (%)	Overestimation frequency (%)	Reserve costs (%)	$f\_reserve(1500€)$ (%)
SLR	0.00	0.00	0.000	0.00
$\tau = 1\%$	0.61	0.72	0.016	0.17
$\tau = 20\%$	0.97	4.17	0.105	1.30
Risk-neutral strategy	1.01	3.62	0.085	1.10
Perfect forecast	1.10	0.00	0.000	0.00

Several results are noteworthy. We start by comparing the results with existing literature. Regarding levels of benefits, we consider study [5], where DLR is considered for dispatching on an IEEE 30-bus grid and benefits of around 1% of the operational costs are found. Here, as shown in Table I, we find

benefit values ranging from 0.2% to 1.1%. Regarding total operational costs, we find a mean value of 40k€ per hour.

Results comparable to the literature are also found if we consider the ratio between the activated reserve costs and the benefits. For a risk-neutral approach, the ratio between reserve costs (0.085%) and benefits (1.01%), i.e. a ratio of 1 to 12, is close to that found in [22].

Compared to the use of 1% quantile forecasts, the use of a high-quantile (i.e.  $\tau=20\%$ ) or risk-neutral strategy increases the benefits by 60%, going from 0.61% to 0.97% and 1.01% respectively. Unfortunately, this is linked with a seven-fold increase of the charges paid by the TSO and of the number of large accidents (expressed by the last column in Table I).

In terms of benefits, a dynamic risk-neutral strategy provides slightly better benefits compared to using high quantiles but a quite significant reduction (by  $\sim 15\%$ ) of the number of incidents (from 1.3% down to 1.1%).

Thus, the dynamic selection of a level of probability for the forecast brings advantages compared to a fixed quantile. However, although the required activated amount of reserve is reduced, it is still far higher than that resulting from the use of a conservative DLR forecast (i.e.  $\tau=1\%$ ), with the TSO's charges and the number of incidents respectively multiplied by 5 (for the risk-neutral strategy) and 7 (for  $\tau=20\%$ ).

### B. Evaluation with Risk-Averse Strategies

In this second part, DLR forecast are calculated as before (optimised fixed quantile  $\tau$  and variable quantile) with the difference that the expected revenue function is filtered with the  $v_\beta$  function described in equation (8-10).

The evolution of operational cost linked to the DLR is followed by modifying the values of the probability  $\tau$  and the parameter  $\beta$ . The values of  $\beta$  are selected with the following numerical sequence:

$$\beta_k = 10^{\frac{k-\alpha}{20}} \quad (13)$$

For each function  $v_\beta$ , the parameters  $\alpha$  and the amount of  $\beta$  values are set such that for the first 5 and last 5 problems solved, the benefits observed do not vary.

In Fig. 7, for each level of benefits observed with the variations of  $\beta$ , the value of the total DLR forecast error costs is represented.

As we can see, for each level of benefits, linear penalties generate significant improvements in terms of reducing the total error costs. On the other hand, no improvement is observed with the use of quadratic penalties whilst the application of exponential penalties results in a worsening of the performance.

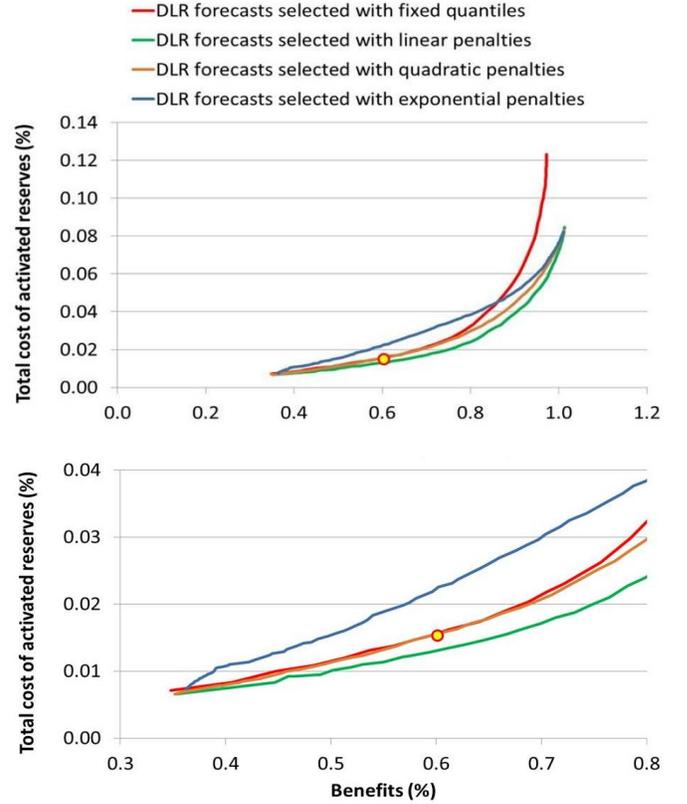


Fig. 7. Total error DLR forecast costs in function of economic benefits, depending on the use of a fixed quantile (red) or a dynamic selection, set with linear penalties (green), quadratic penalties (orange) and exponential penalties (blue). The yellow circle is associated with the use of 1% DLR quantile forecasts. The lower figure is a zoom of the upper one for the benefits in the area between 0.3% and 0.8%.

Fig. 8 shows the evolution of the frequency of incidents with the observed benefits.

In contrast to what we observed with the evolution of total costs, ranking the different risk-averse strategies is complex here. Although better results are observed with the use of quadratic and exponential penalties compared to linear penalties, this ranking is not as clear as that observed in Fig. 7, especially for benefit levels close to those associated with the use of 1% quantile forecasts. This is mainly due to the quality of DLR forecasts for very low quantiles ( $\leq 1\%$ ). Whereas linear penalties penalize the different potential overestimates with linear weights, and thus are only slightly sensitive to the quality of extreme quantile forecasts, this is not the case with quadratic and exponential penalties. The forecasts used in this paper have been designed to provide results similar to those presented in the literature, with no focus on the quality of the forecasts for probability levels lower than 1%. It is thus not surprising that the quadratic and exponential strategies perform poorly for benefit levels associated with the use of low-quantile DLR forecasts ( $\approx 0.61\%$ ).

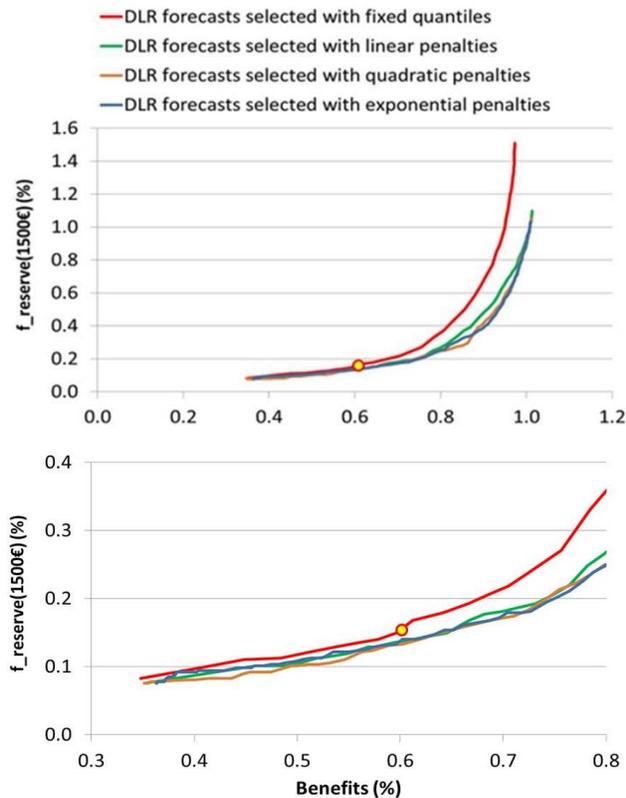


Fig. 8. Frequency of incidents in function of economic benefits, depending on the use of a fixed quantile (red) or a dynamic selection, set with linear penalties (green), quadratic penalties (orange) and exponential penalties (blue). The yellow circle is associated with the use of 1% DLR quantile forecasts. The lower figure is a zoom of the upper one for the benefits in the area between 0.3% and 0.8%.

## V. CONCLUSIONS

Recently, the use of two-stage stochastic optimization problems for setting DLR forecasts has been investigated in the literature. However, most of these studies propose risk-neutral strategies, in which the DLR forecast setting only aims at optimizing social welfare, and the TSO's risk aversion is not considered. As a result of this last point, a TSO may still prefer to continue setting DLR forecasts using fixed quantiles, thus disregarding the potential benefits of more developed strategies.

In this paper, we have proposed new methods for setting DLR using DLR probabilistic forecasts and the solving of a bilevel stochastic optimization problem, taking into account a risk aversion function. The results are promising: while ensuring low costs for the TSO or a low frequency of incidents, the benefits associated with DLR forecasts could be relatively improved to the order of 20%.

This work opens up several research topics. First, the proposed methodology uses DLR quantile forecasts with probability levels below 1%. Such DLR forecasts have not been investigated in the literature to date, and the interest of such forecasts is demonstrated here. Secondly, the methodology requires several forecasts of load and energy production, and a frame would need to be defined for such applications with other stochastic features. Finally, we have shown that the choice of penalty function has an important impact on the final result. For the illustration of the potential benefits, evaluation indices and

penalty functions have been arbitrarily defined. Further work should be carried out in the future to define them so as to reflect in a more realistic way the objectives of a specific TSO.

## ACKNOWLEDGEMENT

The European Centre for Medium-Range Weather Forecasts (ECMWF) is acknowledged for the provision of the Numerical Weather Predictions. The authors would like to thank Prof. M. Matos of INESC TEC for our useful discussions.

## REFERENCES

- [1] W. CIGRE, *12, Thermal Behaviour of Overhead Conductors, Tech. Brochure*, 2002.
- [2] "IEEE Standard for Calculating the Current-Temperature Relationship of Bare Overhead Conductors," *IEEE Std 738-2012 Revis. IEEE Std 738-2006 - Inc. IEEE Std 738-2012 Cor 1-2013*, pp. 1–72, Dec. 2013.
- [3] T. O. Seppa, "Guide for selection of weather parameters for bare overhead conductor ratings," *CIGRE WG B*, vol. 2, 2006.
- [4] M. W. Davis, "A new thermal rating approach: The real time thermal rating system for strategic overhead conductor transmission lines – Part I: General description and justification of the real time thermal rating system," *IEEE Trans. Power Appar. Syst.*, vol. 96, no. 3, pp. 803–809, May 1977.
- [5] M. A. Bucher, M. Vrakopoulou, and G. Andersson, "Probabilistic N-1 security assessment incorporating dynamic line ratings," in *IEEE Power Energy Society General Meeting*, Vancouver, Canada, 2013.
- [6] M. Khaki, P. Musilek, J. Heckenbergerova, and D. Koval, "Electric power system cost/loss optimization using dynamic thermal rating and linear programming," in *Electric Power and Energy Conference (EPEC), 2010 IEEE*, Halifax, Canada, 2010.
- [7] C. J. Wallnerström, Y. Huang, and L. Söder, "Impact From Dynamic Line Rating on Wind Power Integration," *IEEE Trans. Smart Grid*, vol. 6, no. 1, pp. 343–350, Jan. 2015.
- [8] D. M. Greenwood and P. C. Taylor, "Investigating the Impact of Real-Time Thermal Ratings on Power Network Reliability," *IEEE Trans. Power Syst.*, vol. 29, no. 5, pp. 2460–2468, Sep. 2014.
- [9] A. Michiorri *et al.*, "Forecasting for dynamic line rating," *Renew. Sustain. Energy Rev.*, vol. 52, pp. 1713–1730, Dec. 2015.
- [10] I. Albizu, E. Fernandez, A. J. Mazon, K. J. Sagastabeitia, M. T. Bedialauneta, and J. G. Olazarri, "Overhead line rating forecasting for the integration of wind power in electricity markets," in *2015 International Conference on Clean Electrical Power (ICCEP)*, Taormina, Italy, 2015, pp. 382–388.
- [11] H.-M. Nguyen, J.-L. Lilien, and P. Schell, "Dynamic line rating and ampacity forecasting as the keys to optimise power line assets with the integration of res. The European project Twenties Demonstration inside Central Western Europe," presented at the CIRED, Stockholm, Sweden, 2013, p. 0946.
- [12] H.-M. Nguyen, J.-J. Lambin, F. Vassort, and J.-L. Lilien, "Operational experience with Dynamic Line Rating forecast-based solutions to increase usable network transfer capacity," *Proc. 45th Sess. Counc. Large Electr. Syst. CIGRE*, 2014.
- [13] H. E. Hoekstra, C. P. J. Jansen, J. Hagen, J. W. Van Schuylenburg, J. S. P. Wisse, and W. J. Zittersteijn, "Weather forecasted thermal line rating model for the Netherlands," in *CIGRE Session*, Paris, France, 2012.
- [14] T. Ringelband, P. Schäfer, and A. Moser, "Probabilistic ampacity forecasting for overhead lines using weather forecast ensembles," *Electr. Eng.*, vol. 95, no. 2, 2013.
- [15] J. L. Aznarte and N. Siebert, "Dynamic Line Rating Using Numerical Weather Predictions and Machine Learning: A Case Study," *IEEE Trans. Power Deliv.*, vol. 32, no. 1, pp. 335–343, Feb. 2017.
- [16] "DLR Forecasting Presented at FERC - Nexans." [Online]. Available: [http://www.nexans.us/eservice/US-en\\_US/navigatepub\\_0\\_-32903/DLR\\_Forecasting\\_Presented\\_at\\_FERC.html](http://www.nexans.us/eservice/US-en_US/navigatepub_0_-32903/DLR_Forecasting_Presented_at_FERC.html). [Accessed: 08-May-2018].
- [17] M. A. Bucher and G. Andersson, "Robust Corrective Control Measures in Power Systems With Dynamic Line Rating," *IEEE Trans. Power Syst.*, vol. 31, no. 3, pp. 2034–2043, May 2016.
- [18] Y. Chen, F. Teng, R. Moreno, and G. Strbac, "Impact of dynamic line rating with forecast error on the scheduling of reserve service," in

- Power and Energy Society General Meeting (PESGM)*, Boston, USA, 2016.
- [19] K. Kopsidas, A. Kapetanaki, and V. Levi, "Optimal Demand Response Scheduling With Real-Time Thermal Ratings of Overhead Lines for Improved Network Reliability," *IEEE Trans. Smart Grid*, vol. 8, no. 6, pp. 2813–2825, 2017.
- [20] B. Banerjee, D. Jayaweera, and S. M. Islam, "Alleviating post-contingency congestion risk of wind integrated systems with dynamic line ratings," in *Power Engineering Conference (AUPEC), 2014 Australasian Universities*, Perth, Australia, 2014.
- [21] B. Banerjee, S. M. Islam, and D. Jayaweera, "Monte Carlo based method for managing risk of scheduling decisions with dynamic line ratings," in *Power & Energy Society General Meeting*, Denver, USA, 2015.
- [22] F. Teng, R. Dupin, A. Michiorri, G. Kariniotakis, Y. Chen, and G. Strbac, "Understanding the Benefits of Dynamic Line Rating under Multiple Sources of Uncertainty," *IEEE Trans. Power Syst.*, vol. 33, no. 3, pp. 3306–3314, 2018.
- [23] B. Banerjee, D. Jayaweera, and S. M. Islam, "Optimal scheduling with dynamic line ratings and intermittent wind power," in *PES General Meeting/ Conference & Exposition, 2014 IEEE*, National Harbor, USA, 2014.
- [24] M. Miura, T. Satoh, S. Iwamoto, and I. Kurihara, "Application of dynamic rating to evaluation of ATC with thermal constraints considering weather conditions," in *2006 IEEE Power Engineering Society General Meeting*, Montreal, Canada, 2006.
- [25] N. Meinshausen, "Quantile Regression Forests," *J. Mach. Learn. Res.*, vol. 7, no. Jun, pp. 983–999, 2006.
- [26] Y. Zhang and J. Wang, "GEFCom2014 probabilistic solar power forecasting based on k-nearest neighbor and kernel density estimator," in *IEEE Power Energy Society General Meeting*, Denver, USA, 2015.
- [27] T. Chen and C. Guestrin, "Xgboost: A scalable tree boosting system," in *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 2016, pp. 785–794.
- [28] G. Ke *et al.*, "Lightgbm: A highly efficient gradient boosting decision tree," in *Advances in Neural Information Processing Systems*, 2017, pp. 3146–3154.
- [29] J. Snoek, H. Larochelle, and R. P. Adams, "Practical bayesian optimization of machine learning algorithms," in *Advances in neural information processing systems*, 2012, pp. 2951–2959.
- [30] X. Sun, P. B. Luh, K. W. Cheung, and W. Guan, "Probabilistic forecasting of dynamic line rating for over-head transmission lines," in *IEEE Power Energy Society General Meeting*, Denver, USA, 2015.
- [31] C. Grigg *et al.*, "The IEEE Reliability Test System-1996. A report prepared by the Reliability Test System Task Force of the Application of Probability Methods Subcommittee," *IEEE Trans. Power Syst.*, vol. 14, no. 3, pp. 1010–1020, Aug. 1999.
- [32] R. Lincoln, *PyPower*. 2017.
- [33] R. Dupin, A. Michiorri, and G. Kariniotakis, "Dynamic line rating day-ahead forecasts - cost benefit based selection of the optimal quantile," presented at the CIREN Workshop, Helsinki, Finland, 2016, pp. 122–126.
- [34] L. Dawson and A. Knight, "Applicability of Dynamic Thermal Line Rating for Long Lines," *IEEE Trans. Power Deliv.*, vol. 33, no. 2, pp. 719–727, 2018.

works at the MINES ParisTech PERSEE Centre as a senior scientist and head of the Renewable Energies and Smart Grids Group. He has authored more than 220 scientific publications in journals and conferences. He has been involved as participant or coordinator in more than 40 R&D projects in the fields of renewable energies and distributed generation. Among them, he was the coordinator of some major EU projects in the field of wind power forecasting such as Anemos, Anemos.plus and SafeWind projects. His scientific interests include among others timeseries forecasting, decision making under uncertainty, modeling, management and planning of power systems.

**Romain Dupin** is a graduate of Ecole Centrale Lille, where he took a Chair of Electrical Networks option, and from the University of Lille 1, where he gained a Master's degree in electrical engineering in 2014. Since September 2014, he has been a PhD student at the MINES ParisTech Center for Processes, Renewable Energies and Energy Systems (PERSEE) in Sophia Antipolis, France. He works on developing methods for forecasting dynamic line rating and studies the impacts of dynamic line rating on power system management.

**Andrea Michiorri** received an Eng. degree in Mechanical Engineering with a specialization in Energy from the University of Rome 'La Sapienza' in 2005. He then obtained a PhD from the University of Durham in 2010 with a dissertation on the thermal state estimation of power system components. He is currently an associate professor at the MINES-ParisTech Center for Processes, Renewable Energies and Energy Systems (PERSEE) in Sophia Antipolis, France, working on the integration of renewable resources and distributed generators into the power system, with a particular focus on the aspects of decision-making under uncertainty.

**George Kariniotakis** (S'95-M'02-SM'11) was born in Athens, Greece. He received his Eng. and M.Sc. degrees from Greece in 1990 and 1992 respectively, and his PhD from Ecole des Mines de Paris in 1996. He currently



## Résumé

Le Dynamic Line Rating est la modification dynamique des contraintes de courant sur une ligne électrique aérienne, en accord avec la météorologie. De telles modifications permettent alors d'avoir des réductions des phénomènes de congestion près de 99% du temps.

De manière similaire aux énergies renouvelables, il est possible de générer des prévisions de ces contraintes modifiées, en accord avec des observations historiques, des prévisions météorologiques et des méthodes d'intelligence artificielle.

Dans cette thèse, nous proposons le développement de modèles de prévision probabilistes à court terme du DLR. Nous nous concentrons plus particulièrement sur des méthodes fournissant des prévisions ayant de très faibles probabilités d'être surestimées. Cela passe par le développement et la comparaison de plusieurs méthodes de prévision, ainsi que des améliorations comme des modifications de prévisions à très bas quantile à l'aide de remodelisations des queues de distribution.

Par la suite, une réflexion est faite sur l'utilisation en pratique de ces prévisions, d'abord par des cas d'étude simplifié, puis à l'aide de simulations de réseaux électrique. Ces approches nous permettent de développer de nouvelles stratégies d'utilisation des prévisions DLR, optimisant le bien-être social tout en maintenant les risques associés aux erreurs de prévision à un niveau faible.

Finalement, nous évaluons les modèles de prévisions développés en fonction de leurs performances économiques à l'aide des modèles de réseaux électriques, et nous démontrons la valeur des améliorations des modèles de prévision que nous proposons.

## Mots-clés

Prévisions, Dynamic Line Rating, Optimisation stochastique, Calculs de flux de puissance.

## Abstract

Dynamic Line Rating is the modification of the maximal current capacity of an overhead electrical line, depending on weather characteristics. Such modifications allow important decreases of congestion phenomena, around 99% of the time.

Similarly to renewable generation, it is possible to forecast the modified constraints, accordingly to some historic observations, weather predictions and artificial intelligence methods.

In this document, the development of short-term probabilistic DLR forecast models. A focus is especially made on methods providing forecasts having a very low probability of being overestimated. This is made through the development and the comparison of several forecast methods, and some improvements such as the remodelling of very low quantile forecasts with tail density modelling.

Following that, a reflection is proposed on the use of such forecasts in practice, first with some simplified test cases, then with electrical grid simulations. These approaches allow us developing new strategies for the use of the DLR forecasts, maximizing the social welfare while keeping risks associated with forecasts errors at low levels.

Finally, an evaluation of the forecast models function of their economic value is made with the electrical grids models, and the value of the proposed modifications of the forecast models is then demonstrated.

## Keywords

Forecasts, Dynamic Line Rating, Stochastic optimization, Power Flows.