



HAL
open science

Caractérisation et prédiction probabiliste des variations brusques et importantes de la production éolienne

Arthur Bossavy

► **To cite this version:**

Arthur Bossavy. Caractérisation et prédiction probabiliste des variations brusques et importantes de la production éolienne. Autre. Ecole Nationale Supérieure des Mines de Paris, 2012. Français. NNT : 2012ENMP0058 . pastel-00803234

HAL Id: pastel-00803234

<https://pastel.hal.science/pastel-00803234>

Submitted on 21 Mar 2013

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.

École doctorale n° 432 : Sciences des Métiers de l'Ingénieur

Doctorat ParisTech

THÈSE

pour l'obtention du grade de docteur délivré par

l'École nationale supérieure des mines de Paris

Spécialité " Énergétique "

soutenue publiquement par

Arthur BOSSAVY

le 06/12/12

Caractérisation et prédiction probabiliste des variations brusques et importantes de la production éolienne

Directeur de thèse : **Didier MAYER**

Co-encadrement de la thèse : **George KARINIOTAKIS, Robin GIRARD**

Jury

M. Eric Matzner-Løber , Professeur des Universités, Laboratoire de Statistiques, Université de Haute Bretagne Rennes II	Rapporteur
M. Vladimiro Miranda , Professeur des Universités, Département d'Ingénierie Electrique et Informatique, Université de Porto	Rapporteur
M. Pierre Pinson , Professeur Associé, Laboratoire de Modélisation Mathématique et d'Informatique, Université Technique du Danemark	Rapporteur
M. Jean-Michel Poggi , Professeur des Universités, Laboratoire de Mathématiques, Université Paris Orsay	Examineur
M. Vincent Lefieux , Docteur, Département Information et Transparence, RTE	Examineur
M. Didier Mayer , Directeur de Recherche, Centre Energétique et Procédés, MINES ParisTech	Examineur
M. George Kariniotakis , Chargé de Recherche, Centre Energétique et Procédés, MINES ParisTech	Examineur
M. Robin Girard , Assistant de Recherche, Centre Energétique et Procédés, MINES ParisTech	Examineur

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

Remerciements personnels

Avant tout, je tiens à remercier mes encadrants : Didier Mayer, Georges Kariniotakis et Robin Girard pour m'avoir offert l'opportunité de faire cette thèse. Je suis arrivé au Centre d'Energétique et Procédés sans aucune expérience dans le domaine de l'énergie, et j'ai beaucoup appris (et continue d'apprendre ...) à vos côtés. Je vous remercie sincèrement d'avoir eu foi en moi et en notre travail, lorsque parfois, j'ai pu me sentir découragé. Avec le recul, je réalise à quel point ces 3 années passées à travailler avec vous ont pu être stimulantes et enrichissantes.

Je tiens également à remercier toutes les personnes avec lesquelles j'ai pu échanger. Une discussion de 5 minutes au détour d'un couloir est souvent plus éclairante que de longues heures de réflexion solitaire. Je tiens particulièrement à remercier Philippe Blanc pour les nombreux échanges que j'ai eus avec lui. Ses conseils m'ont toujours été précieux.

Je remercie également toutes les personnes sans lesquelles notre travail de recherche ne pourrait avancer faute de charges administratives et techniques. Merci donc à : Brigitte, Lylianne, Christine, Marie-Jeanne, Roseline, Manu et Laurent !

Enfin, je tiens à remercier toute ma famille. Le résultat de ce travail est aussi celui de vos encouragements. Merci Maman, Papa, Lala, Léo et Justine. Vous avoir tous le jour de ma soutenance fut un vrai bonheur. Merci aussi à mes amis d'ici et d'ailleurs : Gaël, Kent, Bobby, Claire, Nora, François, Zhipeng, Benjamin, Christophe, Massiel, Yassin, Alfred, Emilie, Giuseppe et tous les autres, trop nombreux pour être tous cités ici !

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

Remerciements professionnels

Tout d'abord, je remercie l'ensemble des partenaires du projet Européen de recherche SAFEWIND dans lequel s'inscrivent ces travaux de thèse. Plus particulièrement, je tiens à remercier Energinet et EDF pour avoir fourni les données de production éolienne, ainsi que ECMWF pour avoir fourni les prévisions météorologiques avec lesquelles j'ai pu travailler. Je remercie également l'ADEME pour avoir en partie financé mes travaux de recherche. Enfin, je tiens à remercier Alexis Bocquet pour son travail d'implémentation sur la plateforme opérationnelle de prédiction du Centre d'Energétique et Procédés, grâce auquel j'ai pu étudié les performances de l'approche développée dans cette thèse sur un grand nombre de données supplémentaires.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

Table des matières

1	Introduction	11
1.1	Contexte général	11
1.2	Prédire la production éolienne et ses extrêmes : le cas des variations brusques et importantes	13
1.3	Objectifs et démarche de la thèse	16
1.4	Structure du manuscrit	17
	Bibliographie	19
2	Caractérisation de la variabilité de la production éolienne	23
2.1	Introduction	23
2.2	Les différents aspects de la variabilité de la production éolienne	25
2.2.1	Variabilité, écart-type, distribution et non-stationnarité du processus de production éolienne	26
2.2.2	Variabilité et analyse spectrale de la production	28
2.2.3	Variabilité et différences finies de la production	30
2.3	Caractérisation et détection des ruptures d'un signal numérique	32
2.3.1	Quelques notions de base dans la détection des ruptures d'un signal numérique unidimensionnel	33
2.3.2	Caractérisation multi-échelle et détection des ruptures d'un signal	38
2.4	Conclusions	45
	Bibliographie	47
3	Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection	53
3.1	Introduction	53

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

3.2	Proposition d'un cadre d'évaluation des approches de détection des variations brusques et importantes de la production éolienne	55
3.2.1	Définition d'un modèle de rupture	55
3.2.2	Conditions expérimentales et simulations	60
3.2.3	Critères d'évaluation	63
3.3	Etude paramétrique du comportement de différents filtres de détection	68
3.3.1	Choix de filtres	68
3.3.2	Evaluation des performances de détection à partir des critères de Canny	68
3.4	Etude paramétrique d'approches de détection multi-échelles	72
3.4.1	Approches multi-échelles	73
3.4.2	Evaluation des performances de détection et de localisation	74
3.5	Conclusions	82
	Bibliographie	84
4	Estimation de l'incertitude temporelle dans la prédiction des variations brusques et importantes de la production éolienne	87
	Première partie : Introduction	87
	Deuxième partie : Forecasting ramps of wind power production with numerical weather prediction ensembles	89
4.1	Introduction	89
4.2	Definition and characterization of a ramp event	91
4.2.1	Measuring time variations of wind power	92
4.2.2	Ramp detection and characterization	93
4.3	Forecasting ramp events using ensemble wind power forecasts	94
4.3.1	Forecasting an ensemble of ramp characteristics	94
4.3.2	Clustering an ensemble of ramp characteristics	95
4.3.3	Making probabilistic forecasts of ramp occurrence using ensembles	96
4.4	Evaluation framework and results	98
4.4.1	The Case-Study	98
4.4.2	Evaluating the capture of ramp events from ensemble-based forecasts	100
4.4.3	Evaluating ensemble-based probability forecasts of ramp occurrence	101
4.5	Conclusions and Perspectives	103
	Troisième partie : Résultats complémentaires	106

TABLE DES MATIÈRES

Bibliographie	109
5 Conclusions générales	113
5.1 Retour sur les contributions et conclusions	113
5.2 Perspectives	115
Bibliographie	117
A Prédiction de l'instant d'apparition d'une rupture - Résultats d'autres cas d'étude	119
A.1 Contenu des résultats	119
A.2 Ferme N°2	120
A.3 Ferme N°3	124
B Liste des publications	129

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

Chapitre 1

Introduction

1.1 Contexte général

DANS les décennies à venir les besoins énergétiques vont continuer à augmenter dans le monde. L'Agence Internationale de l'Energie estime à 36% l'accroissement de la demande mondiale en énergie primaire¹ pour la période 2008-2035 [1]. Cette demande supplémentaire se situera majoritairement dans les pays émergents. L'énergie produite pour répondre à la demande globale proviendra en premier lieu de la combustion de ressources fossiles. De récentes études soulignent le rôle que joue leur exploitation dans l'augmentation des concentrations atmosphériques en gaz à effet de serre et l'incidence de cette augmentation sur le réchauffement climatique [2]. La sensibilisation des populations aux questions environnementales pousse aujourd'hui les instances dirigeantes à agir pour le développement de sources d'énergie durables et plus respectueuses de l'environnement.

En décembre 2008, la Commission Européenne a adopté une série de mesures visant une réduction des émissions de gaz à effet de serre et un accroissement de l'efficacité énergétique de 20% pour la période 1990-2020 [3]. Ses directives prévoient également de relever à 20% la part des sources renouvelables dans la consommation d'énergie et placent l'Europe en tête des économies industrialisées respectueuses de l'environnement. Aux Etats-Unis, des quotas destinés à promouvoir les énergies renouvelables ont d'ores et déjà été instaurés dans 30 états [4]. A l'heure où la crise jette des doutes quant à la capacité de l'Europe à tenir ses engagements et bloque l'adoption d'une législation américaine au niveau fédéral, la Chine ne semble elle pas marquer le pas. Devenu le premier consommateur d'énergie au monde, sa politique énergétique révèle aujourd'hui des objectifs proches de ceux de l'Union Européenne avec notamment 15% d'énergie d'origine renouvelable à l'horizon 2020 [5].

Parmi les énergies renouvelables on compte principalement les énergies : hydraulique,

1. Une source d'énergie primaire désigne une forme d'énergie disponible dans la nature. Afin d'être utilisable, il peut être nécessaire de transformer celle-ci. On la distingue ainsi de l'énergie dite finale, qui désigne l'énergie consommable.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

solaire thermique et photovoltaïque, éolienne, ainsi que la biomasse et la géothermie. L'énergie éolienne est parmi les énergies renouvelables celle ayant connu la plus forte expansion lors de la dernière décennie. La capacité installée dans le monde s'est accrue en moyenne d'environ 30% chaque année et est passée de 17 GW en 2000 à 197 GW en 2010 [6]. Le fort développement actuel de l'éolien peut s'expliquer par plusieurs raisons. Tout d'abord, par l'immensité de la ressource disponible. Certaines études l'estiment suffisante pour subvenir à l'ensemble des besoins actuels en énergie [7, 8]. Un autre facteur favorable au développement de l'éolien est son coût qui, pour l'éolien onshore, est l'un des plus faibles parmi ceux des différentes sources d'énergie renouvelables [9].

L'accroissement des capacités de production se traduit par un accroissement de la pénétration² de l'éolien dans les systèmes électriques. Dans les systèmes où les taux de pénétration sont parmi les plus élevés, ce sont près de 20% de la demande annuelle en électricité qui est fournie par la production éolienne [10]. La coordination de cette dernière avec la production issue d'autres ressources est la tâche d'opérateurs chargés de maintenir en permanence l'équilibre entre la production et la demande en électricité. Du fait de la nature variable de la production éolienne, il est le plus souvent nécessaire de faire appel à des réserves supplémentaires afin de maintenir cet équilibre [11, 12]. Bien souvent, ces réserves sont fournies par des ressources conventionnelles. Outre les émissions supplémentaires de CO₂, cette démarche a pour effet d'accroître les coûts imputables à la production d'énergie éolienne. Certaines études estiment ainsi qu'au delà d'une pénétration représentant 20% de la production totale en électricité, les bénéfices relatifs à une large intégration de l'éolien (économies d'échelles, développement technologique...) se trouvent contre-balançés par entre autres l'accroissement des coûts liés au besoin de réserves supplémentaires et la nécessité de produire à partir de sites moins favorables (voir notamment [13]).

Pour assurer l'équilibre entre l'offre et la demande en électricité, les opérateurs doivent planifier la production quelques jours (resp. heures) à l'avance. Pour ce faire, ils disposent de divers outils et informations : des prédictions de la demande, des algorithmes d'optimisation permettant de sélectionner les unités de production nécessaires à moindre coût. Ils peuvent aussi se reposer sur des prédictions de la production de sources variables, notamment sur des prédictions de la production éolienne. Ces dernières permettent aujourd'hui de faciliter diverses opérations de gestion. Il peut s'agir entre autres de la quantification des réserves [14] ou de la planification de l'opération combinée avec d'autres sources d'énergie renouvelables ou de stockage, comme l'énergie hydraulique par exemple [15]. Dans un contexte de libéralisation des marchés de l'électricité, la prédiction de la production éolienne s'est également révélée être utile dans le développement de stratégies d'enchères [16, 17]. La mise au point et l'étude d'approches permettant de mieux prédire la production éolienne sont ainsi reconues comme un enjeu majeur du développement de l'éolien [18].

2. Il existe différentes définitions de la pénétration éolienne dans un système électrique. Il peut s'agir du rapport entre : la production éolienne et la demande en un instant donné ou pour une certaine période de temps, la production éolienne et la production globale, ou encore entre la capacité éolienne installée et le pic de demande en électricité enregistré dans une année. Si besoin est, nous préciserons à quelle définition le terme de "pénétration" fait référence.

1.2 Prédire la production éolienne et ses extrêmes : le cas des variations brusques et importantes

Lorsque l'on cherche à prédire la production éolienne, il est nécessaire de clairement identifier les échelles d'espace et de temps concernées. La pertinence des informations sur lesquelles peuvent reposer des prédictions de la production dépend ainsi des échéances auxquelles ces dernières sont destinées. L'évolution récente des conditions météorologiques et de production, mesurée dans les environs plus ou moins proches d'une ferme, constitue l'information nécessaire à la prédiction de la production pour des horizons allant de quelques minutes à quelques heures. L'apparition d'une variation brusque et importante dans la production d'une ou d'un ensemble de fermes au passage d'un front par exemple, peut ainsi permettre d'anticiper sa propagation rapide à d'autres fermes connectées au réseau [19]. Ces prédictions à très court terme sont utiles pour affiner les estimations de réserves et dans les procédures d'équilibrage du système qui ont lieu dans les dernières heures précédant l'échéance. Ceci dit, une première planification de ces opérations doit avoir lieu un ou plusieurs jours à l'avance, ce qui requiert des prédictions de la production éolienne couvrant des périodes de temps plus longues.

Pour prédire la production éolienne pour des horizons allant de quelques heures à quelques jours, la démarche usuelle compte alors deux étapes successives. La première étape consiste à prédire à l'aide de modèles numériques (communément appelés *Numerical Weather Prediction* (NWP) *models*) l'évolution des conditions météorologiques, et plus particulièrement du vent, à proximité du ou des sites de production. Il s'agit dans un deuxième temps de convertir ces prédictions de vent en prédictions de puissance. Chacune de ces étapes influe sur la précision avec laquelle la production peut être prédite. La prédictibilité des conditions météorologiques impose ses limites à la prédictibilité de la production éolienne. L'incertitude associée aux prédictions météorologiques, utilisées en entrée des modèles de prédiction de la production éolienne, peut encore se trouver amplifiée (parfois réduite) par le processus de conversion en puissance.

La dispersion géographique des fermes éoliennes sur un territoire permet de bénéficier d'un effet de lissage de leur production agrégée. En effet, à mesure que croît le nombre de fermes connectées au réseau, et ainsi la distance séparant ces fermes, leurs productions à un instant donné s'en trouvent moins corrélées, ce qui a pour effet de réduire la variabilité de leur production totale [20, 21, 22, 23]. Ceci a en outre pour conséquence d'accroître la prédictibilité de la production, et le développement d'approches destinées à prédire la production régionale d'un ensemble de fermes a ainsi fait l'objet de divers travaux de recherche (pour plus de détails nous renvoyons le lecteur à [24]). Pour autant, les efforts consentis dans l'installation de nouvelles fermes ont principalement pour objectif de maximiser la production moyenne de ces dernières. Cette installation se fait, en général, sans égard vis à vis d'une possible réduction de la variabilité de la production [25]. Il en résulte le développement de systèmes électriques dans lesquels la capacité de production éolienne se trouve plus ou moins

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

concentrée dans des zones potentiellement réduites. Cette concentration accroît ainsi la variabilité et favorise l'apparition de brusques et importantes variations dans la production éolienne. Ce phénomène s'observe aussi à moindre échelle dans le cas de fermes offshore où il mobilise l'attention davantage sur des aspects locaux de la gestion du réseau, du fait notamment de l'isolement des fermes en questions et des possibilités limitées en termes d'interconnexions.

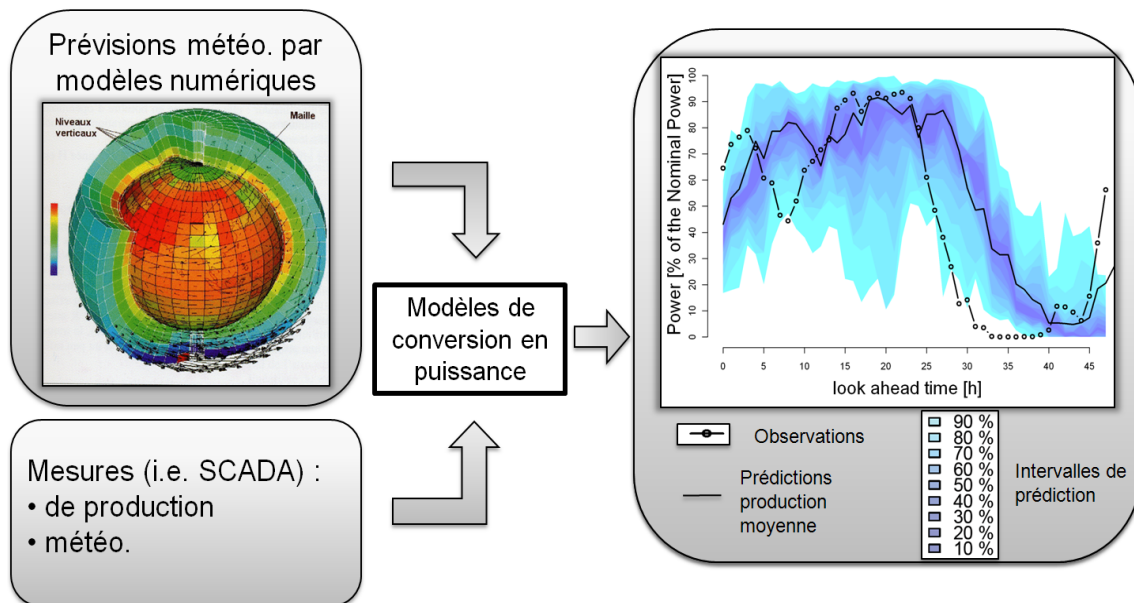


FIGURE 1.1 – Processus de prédiction à court terme de la production – Schéma représentant les différentes étapes du processus de prédiction de la production éolienne. Les informations provenant de modèles météorologiques NWP (e.g. prédictions de la vitesse et de la direction du vent) sont combinées avec des mesures (e.g. de production) à travers des modèles de conversion en puissance. Ces derniers sont destinés à fournir une estimation du niveau de production et de l'incertitude associée. Ces estimations sont généralement des estimations marginales, i.e. elles sont fournies horizon par horizon.

L'apparition d'une variation brusque et importante dans la production éolienne a cela de problématique que toute erreur dans sa prédiction est potentiellement synonyme d'un important déséquilibre énergétique. Ainsi, une erreur de quelques heures dans la prédiction de l'instant de son apparition peut se traduire par un écart significatif entre la quantité d'énergie escomptée et celle réellement produite au cours d'une période donnée. Sa concomitance avec une erreur similaire dans la prédiction de la demande accentue la menace que peut représenter un tel aléa pour l'équilibre du système. C'est précisément le scénario qui s'est produit le 26 février 2008 dans le système électrique géré par le conseil du Texas [26]. Une brusque chute de la production éolienne s'est produite alors même que le système enregistrait son habituel pic de demande de la soirée. Ces événements, arrivant tous deux plus tôt que prévus, se sont trouvés coïncider avec la perte inattendue de ressources d'origine

conventionnelle. Tout ceci a entraîné un rapide déclin des réserves primaires³ puis de la fréquence du système, obligeant ainsi ERCOT⁴ à déclencher l'alerte de niveau 2 de son plan d'urgence et à interrompre l'approvisionnement d'industries et de commerces sous contrat. Il apparaît toutefois qu'au moment de cet incident, ERCOT n'avait pas encore pu intégrer dans son système les prédictions fournies par son prestataire contractuel. Les décisions qui ont pu être prises ont ainsi reposé sur des estimations de la production fournies par un organisme⁵ certifié par ERCOT, et dont la précision s'est avérée moins satisfaisante. En bénéficiant de prédictions plus précises, notamment en ce qui concerne l'instant d'apparition de ces événements, ERCOT aurait peut-être pu être à même de correctement planifier la quantité de réserves nécessaires au bon moment, et ainsi, n'aurait pas eu à dédommager certains usagers [26].

Le processus de conversion en puissance des prédictions météorologiques peut être, dans une certaine mesure, responsable d'une mauvaise estimation des caractéristiques des variations de la production. Toutefois, parce qu'elles dictent la structure temporelle des prédictions de la production, les NWP sont souvent identifiées comme étant la source des erreurs dans la prédiction de l'instant d'apparition de variations brusques et importantes [27]. Les modèles de prédiction de la production éolienne, qui se résument à des approches avancées de conversion en puissance, ne peuvent corriger ces erreurs (sauf peut-être pour les horizons les plus courts, lorsqu'ils utilisent des mesures récentes de la production). De plus, si accroître la résolution des modèles NWP doit permettre de mieux prédire certaines des variations en questions causées par des phénomènes méso- ou micro-échelle, cela ne garantit pas nécessairement une réduction de ces erreurs. En effet, ces dernières proviennent souvent de la mauvaise estimation des conditions initiales (et/ou limites) fournies par les modèles de circulation générale (*Global Circulation Models* (GCM)) et utilisées en entrée des modèles à plus haute résolution [28].

Puisque l'information primordiale que souhaitent connaître les utilisateurs demeure le niveau de production à un instant donné, la majorité des modèles sont aujourd'hui dédiés à l'estimation du niveau de production moyen, ainsi qu'à celle de l'incertitude associée. Pour autant, ces derniers ne permettent pas de quantifier de manière explicite l'incertitude associée à l'estimation des caractéristiques des variations de la production. Ainsi, si l'existence d'erreurs dans la prédiction de l'instant d'apparition de variations brusques et importantes de la production a été rapportée depuis un certain temps déjà [29, 30], des modèles spécifiquement dédiés à l'estimation de ces erreurs restent à développer. Leur utilisation dans les processus de décision pourrait s'avérer bénéfique à une meilleure intégration de l'éolien [31]. Leur développement nécessite en premier lieu d'établir une caractérisation des variations de la production, permettant d'en définir le caractère brusque et important.

3. On distingue différents types de réserves selon l'échelle de temps concernée. Pour une échelle allant de quelques secondes à quelques minutes, les réserves dites primaires sont activées de manière automatique afin de pallier les fluctuations de la fréquence du système.

4. Electric Reliability Council Of Texas

5. QSE : Qualified Scheduling Entity

1.3 Objectifs et démarche de la thèse

L'objectif principal de cette thèse est d'améliorer la prédictibilité de la production éolienne en situations de variations brusques et importantes. En ce sens, il s'agit notamment de proposer une approche de prédiction probabiliste de l'instant d'apparition de ces variations. Les horizons de prédiction concernés vont de quelques heures à quelques jours.

Dans un premier temps, nous nous proposons de définir une méthodologie de caractérisation et de détection des variations brusques et importantes apparaissant dans les signaux de production éolienne. L'étude approfondie des conditions de production sous-jacentes pourrait à terme permettre de mieux comprendre et prédire les phénomènes qui en sont responsables. Pour atteindre cet objectif, nous avons tout d'abord réalisé une analyse bibliographique des approches présentes dans la littérature éolienne et de traitement du signal. Dans la littérature éolienne, la caractérisation de ces variations fait généralement intervenir une forme de filtrage dédiée à la mesure des variations d'un signal de production. Cette approche de filtrage n'a été que peu (ou pas) étudiée. A notre connaissance, il n'en existe pas d'évaluation quantitative vis-à-vis d'un quelconque critère de performances. Dans cette thèse, nous nous proposons d'étudier différentes formes de filtrage vis-vis d'un modèle de variation et de critères de performances. Il s'agit d'étudier les performances de ces filtres vis-à-vis d'un modèle de variation représentatif des caractéristiques de la production (e.g. processus borné et non-stationnaire), et ainsi d'en évaluer certaines propriétés de manière quantitative : robustesse au bruit, précision dans la localisation d'une variation, etc. Nous étudions notamment les potentialités de caractérisation qu'offrent ces approches de filtrage vis-à-vis du caractère multi-échelle d'une variation. Tout ceci nous permet d'établir les propriétés requises d'une méthodologie adaptée dans la caractérisation et la détection des variations brusques et importantes de la production éolienne.

Pour répondre à leurs besoins, les gestionnaires de réseaux et autres utilisateurs disposent souvent d'informations concernant la production éolienne future, provenant non pas d'un mais de plusieurs scénarii. Ces scénarii proviennent généralement de prédictions météorologiques issues de différents modèles NWP, ou de la perturbation d'un même modèle. L'utilisation de ces scénarii dans les divers processus de décision fait aujourd'hui l'objet de nombreux travaux de recherche. Elle peut être directe, comme dans le cas d'algorithmes d'optimisation stochastique de la planification de la production [32, 33]. Elle peut également faire intervenir une transformation de ces scénarii sous une autre forme d'information probabiliste, e.g. fonction de densité de probabilité du niveau de production (voir entre autres [34]). Dès lors, l'estimation de cette dernière est presque toujours réalisée pour certains instants dans le futur, correspondant aux horizons de prédiction des prédictions météorologiques sur lesquelles elle repose. Les modèles usuels en offrent une estimation globalement fiable [35, 36]. Cependant, une erreur dans la prédiction de l'instant d'apparition d'une variation brusque et importante de la production peut résulter épisodiquement, en une baisse de fiabilité des estimations lors de ces situations [37].

Nous développons dans le cadre de cette thèse, une approche de prédiction destinée à l'estimation de l'instant d'apparition des variations brusques et importantes de la production, ainsi qu'à celle de l'incertitude associée. L'approche proposée repose sur l'utilisation de scénarii de la production. Ces scénarii sont le résultat de la conversion en puissance d'un ensemble de prédictions météorologiques issu de la perturbation stochastique d'un même modèle. Il est question à travers cette approche, de chercher à exploiter l'information (temporelle) fournie par différents scénarii dans la prédiction d'une variation de la production. Cette approche repose dans un premier temps sur la création, à partir des estimations fournies par les différents scénarii, d'une nouvelle estimation de l'instant d'apparition d'une variation. Dans un second temps, nous cherchons à estimer l'incertitude associée. Cette incertitude est représentée sous la forme d'intervalles de confiance temporels centrés en l'instant d'apparition moyen d'une variation. L'estimation de l'incertitude en question se présente alors sous la forme d'estimations de la probabilité d'apparition d'une variation dans ces intervalles.

Nous évaluons les performances de notre approche sur des données de production réelles. Nous considérons les données de production provenant de trois fermes différentes, couvrant une période de un an et demi. Les prédictions météorologiques ensemblistes utilisées lors de cette évaluation sont issues du modèle EPS de ECMWF. Nous évaluons la précision des prédictions de l'instant d'apparition des variations brusques et importantes de la production fournies par notre approche. Nous évaluons également la fiabilité et la finesse des estimations d'incertitude associées.

1.4 Structure du manuscrit

Dans le chapitre 2, nous présentons tout d'abord les différentes formes de caractérisation de la variabilité de la production rencontrées dans la littérature. Nous expliquons en quoi elles ne permettent pas d'aboutir à une caractérisation satisfaisante des variations brusques et importantes de la production. Puis nous décrivons les techniques usuelles de détection de *ruptures*⁶ d'un signal basées sur l'usage de filtres détecteurs. Nous expliquons certaines notions de base propres à la détection de ruptures à partir de la mise en relation des propriétés d'une variation (géométrie, proximité de ruptures voisines, présence de bruit, etc), avec celles du filtre de détection employé (e.g. forme, largeur). Nous discutons également des approches reposant sur l'emploi d'un filtre à différentes échelles, et offrant une caractérisation des variations qui tienne compte de l'aspect multi-échelle de ces dernières.

Dans le chapitre 3, nous proposons un modèle de rupture dans le but d'évaluer de manière quantitative les performances de détection de certains filtres et approches rencontrés dans la littérature. Nous proposons une modélisation adéquate vis-à-vis des caractéristiques

6. Le terme de "rupture" est couramment employé dans la littérature de traitement du signal pour désigner une variation brusque et importante d'un signal. Dans la littérature éolienne, il est souvent fait référence au terme de "rampe". Le terme de "rampe" est parfois employé dans la littérature de traitement du signal pour désigner une géométrie particulière de rupture. Dans la suite du document, les termes de "rupture" et de "variation brusque et importante" seront utilisés de manière indistincte.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

du processus de production (e.g. processus borné et non-stationnaire), et de ses variations. A partir de simulations issues de ce modèle, nous réalisons une étude paramétrique destinée à évaluer l'influence des caractéristiques des ruptures d'un signal sur les performances de détection de différents filtres. Dans un deuxième temps, et à partir d'un filtre adapté, nous étudions les performances de différentes approches multi-échelles de détection.

Le chapitre 4 est consacré au développement d'une nouvelle approche destinée à prédire de manière probabiliste l'instant d'apparition des variations brusques et importantes de la production. L'approche que nous proposons repose sur le filtrage, à une échelle donnée, de différents scénarii de la production. De ce filtrage est dérivée une estimation de l'instant d'apparition moyen des variations. L'estimation de l'incertitude associée prend la forme d'intervalles de confiance temporels, associés à des estimations de la probabilité d'apparition d'une variation dans ces intervalles. Ce chapitre se présente sous la forme d'une brève introduction, suivie d'un article que nous avons publié dans un journal de rang A [38], puis d'une troisième partie constituée de résultats complémentaires. Des résultats provenant de l'étude de notre approche sur des données de production issues d'autres fermes éoliennes sont présentés en annexe.

Les conclusions de nos travaux, ainsi que certaines des perspectives qu'ils peuvent offrir, sont finalement présentées dans le chapitre 5.

Bibliographie

- [1] International Energy Agency. *World Energy Outlook 2010*. IEA Publications, 2010. [Available online : <http://www.worldenergyoutlook.org>].
- [2] Intergovernmental Panel on Climate Change. *Climate Change 2007 : The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. [Available online : http://www.ipcc.ch/publications_and_data/ar4/wg1/en/contents.html].
- [3] Communiqué de presse de l'Union Européenne. *La Commission salue l'adoption du paquet «Climat et énergie»*. [Available online : <http://europa.eu/rapid/pressReleasesAction.do?reference=IP/09/628&format=HTML&aged=0&language=FR&guiLanguage=fr>].
- [4] U.S. Energy Information Administration. *Annual Energy Outlook 2011*. [Available online : <http://www.eia.gov/forecasts/aeo/pdf/0383>].
- [5] E. Martinot and L. Junfeng. *China's latest leap : An update on renewables policy*. *Renewable Energy World* 13(4) : 51-57, 2010. [Available online : <http://www.renewableenergyworld.com/rea/news/article/2010/07/renewable-energy-policy-update-for-china>].
- [6] Global Wind Energy Council. *Global Wind 2010 Report*. Brussels, Belgium, Tech. Rep., 2010. [Available online : http://www.gwec.net/fileadmin/images/Publications/GWEC_annual_market_update_2010_-_2nd_edition_April_2011.pdf].
- [7] C.L. Archer and M.Z. Jacobson. Evaluation of global wind power. *Journal of Geophysical Research Atmospheres*, 110 :D12110, 2005.
- [8] X. Lu, M.B. McElroy, and J. Kiviluoma. Global potential for wind-generated electricity. *Proceedings of the National Academy of Sciences of the United States of America*, 106(27) :10933–10938, 2009.
- [9] M. Lenzen. Current state of development of electricity-generating technologies : A literature review. *Energies*, 3(3) :462–591, 2010.
- [10] World Wind Energy Association. *World Wind Energy Report 2010*. [Available online : http://www.wwindea.org/home/images/stories/pdfs/worldwindenergyreport2010_s.pdf].
- [11] H. Holttinen. Impact of hourly wind power variations on the system operation in the Nordic countries. *Wind Energy*, 8(2) :197–218, 2005.
- [12] H. Holttinen. Estimating the impacts of wind power on power systems - Summary of IEA Wind collaboration. *Environmental Research Letters*, 3 :025001, 2008.
- [13] M. Hoogwijk, D. van Vuuren, B. de Vries, and W. Turkenburg. Exploring the impact on cost and electricity production of high penetration levels of intermittent electricity in OECD Europe and the USA, results for wind energy. *Energy*, 32(8) :1381 – 1402, 2007.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

- [14] R. Doherty and M. O'Malley. A new approach to quantify reserve demand in systems with significant installed wind capacity. *Power Systems, IEEE Transactions on*, 20(2) :587 – 595, 2005.
- [15] E.D. Castronuovo and J.A.P. Lopes. On the optimization of the daily operation of a wind-hydro power plant. *Power Systems, IEEE Transactions on*, 19(3) :1599 – 1606, 2004.
- [16] P. Pinson, C. Chevallier, and G. Kariniotakis. Trading wind generation from short-term probabilistic forecasts of wind power. *Power Systems, IEEE Transactions on*, 22(3) :1148 –1156, 2007.
- [17] J.M. Angarita and J.G. Usaola. Combining hydro-generation and wind energy : Biddings and operation on electricity spot markets. *Electric Power Systems Research*, 77(5-6) :393 – 400, 2007.
- [18] S.E. Thor and P. Weis-Taylor. Long-term research and development needs for wind energy for the time frame 2000-2020. *Wind Energy*, 5(1) :73–75, 2002.
- [19] R. Girard, A. Bossavy, and G. Kariniotakis. Forecasting ramps of wind power production at different time scales. In *European Wind Energy Conference EWEC 2011, Brussels, Belgium*, 2011.
- [20] G. Giebel. *On the benefits of distributed generation of wind energy in Europe*. PhD thesis, Carl von Ossietzky Universität Oldenburg. [Available online : http://www.drgiebel.de/GGiebel_DistributedWindEnergyInEurope.pdf], 2000.
- [21] H. Holttinen. Hourly wind power variations in the Nordic countries. *Wind Energy*, 8(2) :173–195, 2005.
- [22] C.L. Archer and M.Z. Jacobson. Supplying baseload power and reducing transmission requirements by interconnecting wind farms. *Journal of Applied Meteorology and Climatology*, 46 :1701–1717, 2007.
- [23] W. Katzenstein, E. Fertig, and J. Apt. The variability of interconnected wind plants. *Energy Policy*, 38(8) :4400 – 4410, 2010.
- [24] N. Siebert. *Development of methods for regional wind power forecasting*. PhD thesis, MINES ParisTech. [Available online : <http://pastel.paristech.org>], 2008.
- [25] O. Grothe and J. Schnieders. Spatial dependence in wind and optimal wind power allocation : A copula-based analysis. *Energy Policy*, 39(9) :4742 – 4754, 2011.
- [26] E. Ela and B. Kirby. ERCOT event on February 26, 2008 : Lessons learned. Technical report, National Renewable Energy Laboratory, US Department of Energy. [Available online : <http://www.nrel.gov/docs/fy08osti/43373.pdf>], 2008.
- [27] P. Pinson. *Estimation of the Uncertainty in Wind Power Forecasting*. PhD thesis, MINES ParisTech. [Available online : <http://pastel.paristech.org>], 2006.
- [28] N.J. Cutler, H.R. Outhred, I.F. MacGill, M.J. Kay, and J.D. Kepert. Characterizing future large, rapid changes in aggregated wind power using Numerical Weather Prediction spatial fields. *Wind Energy*, 12(6) :542–555, 2009.

- [29] M. Lange. *Analysis of the uncertainty of wind power predictions*. PhD thesis, University Carl von Ossietzky. [Available online : <http://oops.uni-oldenburg.de/volltexte/2003/263/pdf/lanana03.pdf>], 2003.
- [30] C. Möhrle. *Uncertainty in wind energy forecasting*. PhD thesis, University College Cork, National University of Ireland. [Available online : http://download.weprog.com/phd_thesis_moehrlen_2004.pdf], 2004.
- [31] C.W. Potter, E. Gritti, and B. Nijssen. Potential benefits of a dedicated probabilistic rapid ramp event forecast tool. *2009 IEEE/PES Power Systems Conference and Exposition*, 1(3) :409–413, 2009.
- [32] F. Bouffard and F.D. Galiana. Stochastic security for operations planning with significant wind power generation. *Power Systems, IEEE Transactions on*, 23(2) :306–316, may 2008.
- [33] A. Tuohy, P. Meibom, E. Denny, and M. O'Malley. Unit commitment for systems with significant wind penetration. *Power Systems, IEEE Transactions on*, 24(2) :592–601, may 2009.
- [34] P. Pinson and H. Madsen. Ensemble-based probabilistic forecasting at Horns Rev. *Wind Energy*, 12(2) :137–155, 2009.
- [35] A. Costa, A. Crespo, J. Navarro, G. Lizcano, H. Madsen, and E. Feitosa. A review on the young history of the wind power short-term prediction. *Renewable and Sustainable Energy Reviews*, 12(6) :1725–1744, 2008.
- [36] G. Giebel, G. Kariniotakis, and R. Brownsword. The state of the art on short-term wind power prediction - A literature overview. Technical report, ANEMOS EU project, deliverable report D1.1. [Available online : <http://www.anemos-project.eu>], 2003.
- [37] A. Bossavy. Wind power forecasting uncertainty related to ramp events. Master's thesis, MINES ParisTech, 2009.
- [38] A. Bossavy, R. Girard, and G. Kariniotakis. Forecasting ramps of wind power production with numerical weather prediction ensembles. *Wind Energy*, pages n/a–n/a, 2012. DOI : 10.1002/we.526.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

Chapitre 2

Caractérisation de la variabilité de la production éolienne

2.1 Introduction

IL existe une multitude de phénomènes physiques, météorologiques et climatiques affectant la dynamique du vent dans la couche limite de l'atmosphère, et responsables des variations de la production éolienne au cours du temps. Ces variations, comme les phénomènes qui en sont à l'origine, se manifestent à différentes échelles de temps et d'espace. Il peut s'agir de variations diurnes (dus aux effets thermiques), de variations saisonnières, ou encore de variations à plus long terme liées aux variations du climat. Les variations de la production éolienne ne tiennent pas seulement aux changements dans les conditions météorologiques puisque les caractéristiques techniques et le mode de fonctionnement des turbines éoliennes peuvent également être à l'origine de certaines d'entre elles, ou de leur atténuation. Le rotor d'une turbine agit en soi comme un filtre capable de lisser les fluctuations en puissance à l'échelle de quelques (dizaines de) secondes [1]. Certains des composants d'une turbine (e.g. le volant d'inertie) permettent en outre de stocker mécaniquement l'énergie et d'en lisser la production. A l'échelle d'une ferme, il est possible d'accentuer ce lissage en contraignant à une opération réduite certaines des turbines [2]. A travers l'atténuation des fluctuations les plus rapides de la production, l'objet essentiel de ces dispositifs est la fourniture d'un courant électrique répondant aux critères de qualité qui régissent le raccordement d'une ferme au réseau électrique [3].

D'un autre côté, les variations les plus lentes de la production (e.g. saisonnières, inter-annuelles ou décennales) ont une influence sur l'estimation à long terme de la ressource éolienne, et font principalement l'objet d'études de prospection. Il peut s'agir d'études de rentabilité concernant des projets d'installation de parcs éoliens, ou encore d'analyses destinées à soutenir les choix d'orientation des politiques énergétiques. Le calcul de la production moyenne reposant sur des mesures couvrant une période de quelques années, et donc sou-

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

vent trop courte pour capturer l'intégralité de ces variations, peut conduire à une mauvaise estimation du potentiel de production à long terme [4, 5]. Ces variations entrent également en ligne de compte dans un contexte de prédiction à court terme de la production (e.g. pour un horizon de quelques heures à quelques jours). Le processus de conversion du vent en puissance subit des modifications lentes, propres aux échelles de temps correspondant à ces variations. Ainsi, les modèles statistiques de prévision à court terme de la production font souvent l'objet de méthodes d'estimation adaptative de leurs paramètres, afin de mieux capturer les variations à long terme de la production (on pourra voir entre autres [6, 7, 8, 9]).

Dans un contexte de gestion de l'équilibre d'un système électrique, les variations de la production *intermittente*¹ (e.g. éolienne) associées à celles de la demande dictent, de par leur nature partiellement contrôlable, les actions nécessaires au maintien de cet équilibre. La production éolienne (resp. intermittente) est ainsi davantage considérée comme une "demande négative" que comme une ressource participant à l'effort planifié de production pour répondre à la demande². D'un point de vue opérationnel, les actions de régulation visant à assurer cet équilibre peuvent être divisées en deux catégories. Aux échelles de temps les plus courtes (quelques secondes à quelques minutes), des dispositifs automatiques de contrôle intégrés aux unités de production sont chargés de maintenir la fréquence du système à sa valeur nominale. Les réserves de puissance allouées à cette tâche proviennent de la modulation de la production d'unités (en marche) ne fonctionnant pas à leur capacité maximale (*spinning reserves*) [10]. Pour des échelles de temps supérieures à 10 min environ [11], il est ensuite possible de faire appel à d'autres types de réserve : effacements de demande volontaires, unités conventionnelles à déploiement rapide (e.g. turbines à gaz), ou encore pompage hydroélectrique.

De manière générale, l'allocation des réserves est la responsabilité d'opérateurs chargés de planifier la mobilisation des ressources nécessaires (*Unit Commitment*) au maintien de l'équilibre du système. Cette opération de planification se fait dans un souci de minimisation des coûts, sous un certain nombre de contraintes techniques (propres aux caractéristiques des unités de production et du réseau constituant le système) et de sécurité. L'allocation qui en résulte répartit les rôles des divers unités de production selon leur coût d'exploitation et leur flexibilité. Grossièrement, les unités peu chères et peu flexibles (e.g. nucléaire) sont destinées à fournir la production de base, tandis que celles plus flexibles mais plus chères à pallier les fluctuations de la demande (*load following*) et autres événements contingents (pertes soudaines de ressources, erreurs d'une ampleur inattendue dans l'estimation de la production intermittente, etc). Avec l'accroissement des taux de pénétration de l'éolien, se pose la question de savoir en quelle mesure les variations les plus brusques et les plus importantes de la production peuvent porter atteinte à l'équilibre et la sécurité du réseau. Plus précisément, il est question de savoir si les moyens de production conventionnels, possèdent les capacités suffisantes pour répondre aux erreurs de prédiction de ces variations [12].

1. par "intermittente", on entend la production provenant de sources d'énergie qui varie de manière partiellement contrôlable

2. Il est ainsi question de couvrir, à partir des moyens de production conventionnels, la différence entre la demande et la production intermittente (différence souvent qualifiée de *demande nette*)

Caractérisation de la variabilité de la production éolienne

Si les caractéristiques de modulation de la production des unités conventionnelles (i.e. vitesse de démarrage, de hausse et de baisse du niveau de production, etc) sont connues, celles des variations de la production éolienne le sont moins. Les travaux portant sur l'évaluation du caractère brusque et important des variations de la production reposent majoritairement sur le calcul de différences finies [13, 14, 15, 16, 17, 18]. Ils ne couvrent pas certains aspects propres à la mesure des variations d'un signal. Ils n'expliquent généralement pas, par exemple, comment utiliser l'information recueillie à différentes échelles pour caractériser les variations de la production. Une telle forme de caractérisation pourrait permettre de mieux comprendre et quantifier le caractère brusque et important des variations de la production éolienne.

Dans ce chapitre, nous décrivons dans un premier temps les différentes formes de caractérisation de la variabilité de la production rencontrées dans la littérature. Nous nous intéressons principalement aux variations de la production à des échelles de temps allant de quelques minutes à quelques heures. Nous décrivons quels aspects de la variabilité de la production permettent de quantifier les approches présentes dans la littérature. Nous mettons également en évidence l'inadéquation de ces dernières dans la caractérisation des variations brusques et importantes de la production. Dans un deuxième temps, nous décrivons quelques notions de base concernant les approches de détection de ruptures rencontrées dans la littérature de traitement du signal. Nous nous concentrons sur les approches de filtrage appliquées au cas de signaux unidimensionnels. Ces approches se focalisent sur la mesure et la caractérisation d'une variation en tenant compte de sa géométrie et de son aspect multi-échelle. Elles apparaissent ainsi comme particulièrement adaptées à la caractérisation des variations brusques et importantes de la production éolienne. Le reste du chapitre s'organise comme suit : les différentes formes de caractérisation de la variabilité de la production rencontrées dans la littérature éolienne sont présentées Section 2.2. Dans la Section 2.3, nous donnons un état de l'art des techniques développées dans le cadre de la détection des ruptures d'un signal numérique. Enfin, quelques remarques concluant ce chapitre sont données Section 2.4.

2.2 Les différents aspects de la variabilité de la production éolienne

La vitesse du vent et la production éolienne changent constamment. Si le qualificatif d'"intermittent" est aussi employé dans le but de décrire le caractère partiellement contrôlable de la production éolienne, il est davantage fait référence au terme de "variabilité" dès lors qu'il s'agit de décrire son caractère changeant et la nature aléatoire de ses variations. Il existe bien des moyens de caractériser la variabilité de la production. L'écart-type en donne par exemple une estimation "globale". L'analyse spectrale offre une information plus détaillée, dans le sens où elle permet l'estimation des différentes composantes fréquentielles des signaux de production. Cependant, les aspects de la variabilité ainsi quantifiés ne constituent pas nécessairement une information pertinente au regard d'un opérateur responsable du réseau. Un opérateur en charge de l'équilibre entre l'offre et la demande en électricité doit

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

pouvoir évaluer de combien et à quelle vitesse la production intermittente (resp. la demande) varie d'un instant à l'autre.

Dans cette section, nous donnons une synthèse critique des différentes formes de caractérisation de la variabilité de la production les plus fréquemment rencontrées dans la littérature. Nous insistons sur quels aspects de la variabilité elles quantifient ainsi que sur les limitations de ces approches, vis-à-vis de la caractérisation d'une variation nécessaire à la description des variations les plus brusques et les plus importantes de la production.

2.2.1 Variabilité, écart-type, distribution et non-stationnarité du processus de production éolienne

Par variabilité, on entend souvent écart-type d'une variable aléatoire. L'écart-type d'une variable aléatoire réelle mesure l'écart moyen à la valeur moyenne de cette variable. Il quantifie, et par là même résume à un simple nombre, la dispersion (autour de la valeur moyenne) des valeurs que peut prendre cette dernière. Sous certaines hypothèses paramétriques (e.g. de normalité), l'écart-type avec la valeur moyenne caractérisent la distribution statistique d'une variable aléatoire. L'estimation de cette distribution se ramène alors à l'estimation de la valeur moyenne et de l'écart-type de la variable en question. Comme pour la vitesse du vent, l'asymétrie, la nature bornée et mixte³ de la distribution de la production, font qu'une simple hypothèse de normalité n'est généralement pas adaptée à des fins d'estimation de la ressource ou de prédiction de la production. Il est possible d'opérer une transformation (e.g. logistique) préalable des données de production, rendant l'hypothèse de normalité plus appropriée [19, 20].

Le vent confère au processus de production éolienne sa nature non-stationnaire. Un processus aléatoire est dit stationnaire si ses propriétés statistiques persistent dans le temps. Plus précisément un processus $(P_t)_t$, où t désigne le temps, est dit stationnaire si pour tout vecteur de dimension finie quelconque $n : (P_{t_1}, \dots, P_{t_n})$, la distribution de ce dernier reste invariante par translation dans le temps [21], i.e $\forall h, f_{(P_{t_1}, \dots, P_{t_n})} = f_{(P_{t_1+h}, \dots, P_{t_n+h})}$, où f_X désigne la distribution d'une variable aléatoire X . En particulier, le niveau moyen et l'écart-type d'un processus stationnaire restent constants au cours du temps. Le processus de production éolienne est non-stationnaire notamment dans le sens où son niveau moyen et son écart-type varient au cours du temps. Dès lors, sa non-stationnarité peut se manifester de bien des manières : lors d'un épisode de forte volatilité caractérisé par une importante dispersion des mesures de production autour d'une valeur tendancielle, ou lors d'un changement brusque et important du niveau moyen du processus par exemples. On peut aisément se convaincre de la non-stationnarité du processus de production en visualisant les variations de son niveau moyen et de son écart-type, à partir du résultat d'estimations empiriques reposant sur un calcul de moyennes mobiles.

Des estimations trimestrielles réalisées (ici sans moyennes mobiles) sur des données de

3. i.e. continue-discrète. La distribution statistique de la production d'une turbine ou d'une ferme présente généralement une masse atomique en 0 (production nulle), et au niveau de la capacité maximale de production

Caractérisation de la variabilité de la production éolienne

production agrégée du Danemark entre janvier 2006 et septembre 2009 (échantillonnées au 1/4 h), sont représentées Figure 2.1 (graphique de gauche). Ces données de production proviennent de 212 stations de transformation⁴ réparties sur la péninsule du Jutland et l'île de Funen. La hausse, observée ici, du niveau moyen de production et de son écart-type durant les saisons hivernales, concorde avec les observations faites dans [22]. A cette échelle, les variations du niveau de production moyen n'excèdent pas ici 30% de la capacité de production installée. Les variations brusques dont l'amplitude représente une part importante de la capacité totale de production, s'observent généralement à des échelles de temps et d'espace plus petites.

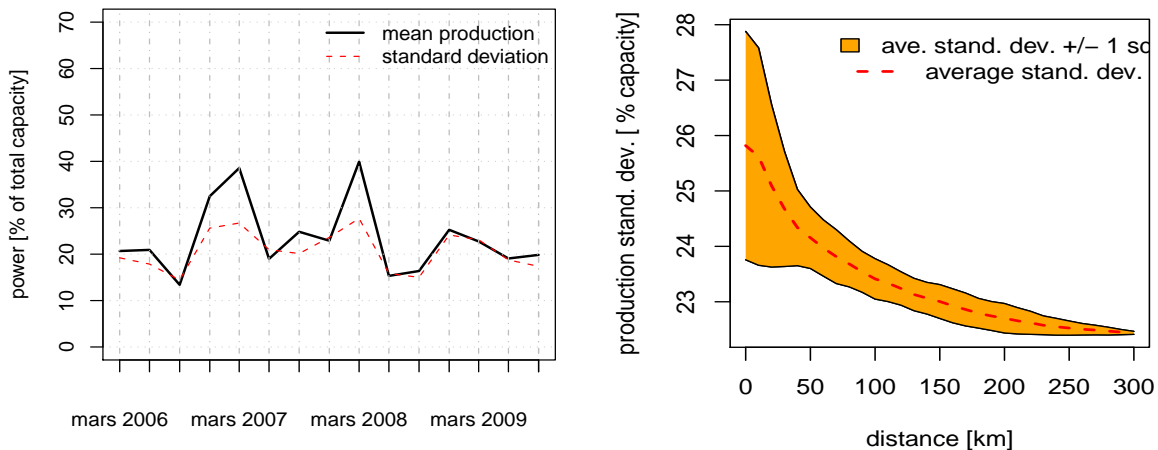


FIGURE 2.1 – Ecart-type de la production : variations temporelles et effet de foisonnement – A gauche : moyennes trimestrielles et écarts-types de la production de la partie ouest du Danemark entre janvier 2006 et septembre 2009. Leurs variations saisonnières montrent la non-stationnarité du processus de production à l'échelle d'un pays. A droite : effet de foisonnement illustré par la diminution de l'écart-type de la production agrégée, lorsqu'augmente la superficie du territoire couvert par des fermes éoliennes.

La dispersion géographique des fermes éoliennes et la diversité des régimes de vent qui y sont associés font que leur production agrégée bénéficie d'un effet dit de *foisonnement*. Ce dernier se caractérise par une production agrégée plus "lisse" que celle de chaque ferme prise indépendamment. Typiquement, la production agrégée tend à ne jamais être nulle, ni à hauteur de sa capacité maximale, et sa distribution voit sa masse se concentrer autour de sa valeur moyenne, à mesure que croît la superficie couverte par des fermes éoliennes. Cette concentration se traduit notamment par une diminution de l'écart-type de la production. En ceci, l'écart-type de la production est souvent étudié afin d'évaluer cet effet de foisonnement [22, 23, 24]. Ce phénomène, montré ici dans le cas de la production Danoise, est illustré Fi-

4. A chacune des stations de transformation auxquelles il est fait référence peut être connectée une ou plusieurs fermes éoliennes. Ces stations sont dorénavant identifiées à des fermes éoliennes.

gure 2.1 (graphique de droite). Les estimations montrées dans cette figure proviennent d'un échantillon de 30 fermes de référence sélectionnées aléatoirement. Dans un premier temps, l'écart-type de la production agrégée des fermes situées dans un rayon allant de 0 à 300 km (par pas de 10 km) d'une ferme de référence a été estimé. Les estimations provenant des différentes fermes de référence ont ensuite été agrégées.

De par sa définition, l'écart-type constitue une mesure appropriée de la volatilité d'un processus comme celui de la production éolienne. Son utilisation a été récemment proposée dans la caractérisation d'épisodes de forte volatilité de la vitesse du vent [25]. L'écart-type quantifie l'intensité avec laquelle un processus fluctue autour de sa valeur moyenne à un instant donné. Il ne permet pas d'évaluer l'intensité ni même la direction avec lesquelles le niveau (moyen) d'un processus varie entre deux instants précis.

2.2.2 Variabilité et analyse spectrale de la production

La description des variations de la production éolienne nécessite la détermination d'échelles de temps (resp. d'espace) caractéristiques. Dans le cas du vent, la disponibilité des mesures a permis depuis longtemps déjà, de mieux comprendre quelles étaient ces échelles. Van der Hoven [26] fut ainsi l'un des premiers à révéler l'existence d'échelles caractéristiques dans la périodicité des variations de la vitesse horizontale du vent. A partir de signaux de mesures réalisées à une altitude de 100m, et pour des fréquences comprises entre 0.25 et 1.95×10^{-7} Hz, il a constaté la présence de variations caractéristiques pour des périodes égales à 1 minute et 4 jours. A chacune de ces variations (i.e. périodes) caractéristiques correspond un "pic significatif" dans la distribution en fréquence de la puissance des signaux de mesures du vent. La distribution en fréquence $S[v]$ de la puissance d'un signal v , est définie par le carré du module de la transformée de Fourier $\mathcal{F}[v]$ du signal, et est parfois appelée *densité spectrale de puissance* :

$$\mathcal{F}[v](f) = \int_{-\infty}^{+\infty} v(t)e^{-2i\pi ft} dt,$$
$$S[v] = |\mathcal{F}[v]|^2,$$

où f désigne la fréquence d'une variation. En pratique, il existe différentes méthodes pour estimer la densité spectrale de puissance à partir d'un nombre fini de mesures. Une approche classique (dite du *périodogramme*, et notamment utilisée dans [26]) repose sur le calcul de la transformée de Fourier discrète du signal. La combinaison des estimations réalisées sur différents segments issus du découpage d'un signal permet d'en réduire la variabilité (pour plus de détails on pourra voir notamment [27] et [28]).

Dans ses travaux, Van der Hoven [26] a également observé l'existence d'un "trou spectral" caractérisé par une faible puissance du signal, pour des variations de la vitesse du vent dont la période était comprise entre 1 minute et 10 heures environ. Les conclusions d'études plus récentes nous amènent toutefois à penser qu'il ne convient pas de généraliser l'existence de

ce dernier [29, 30, 31].

L'étude du spectre de signaux de production éolienne a fait l'objet de récents travaux de recherche [1, 13, 32, 33]. Dans [1], le spectre des signaux de production observée à l'échelle d'une turbine ou d'une ferme ne présente pas de trou spectral, mais fait apparaître une relation exponentielle entre la puissance du signal et les fréquences. Plus précisément, il y est constaté que pour des périodes comprises entre 30 secondes et 2.6 jours, la densité spectrale de puissance suit une exponentielle de la forme : $S[v](f) \propto f^{-5/3}$, f désignant la fréquence. Ces observations corroborent certains résultats théoriques établis par Kolmogorov [34], dans l'étude de l'énergie contenue dans les turbulences d'un fluide (auquel peut être identifiée l'atmosphère). L'adéquation entre ces résultats conduit à identifier le spectre de la production éolienne (d'une ferme) à ce que l'on appelle parfois un *spectre de Kolmogorov* [1]. Dans la continuité de ces travaux, [13] et [32] ont étudié l'effet de foisonnement à travers l'analyse spectrale de signaux représentant la production agrégée de fermes interconnectées. Dans [13], la réduction de la puissance du signal aux fréquences les plus élevées, caractérisant l'effet de foisonnement, est clairement exprimée par la fraction du spectre de Kolmogorov (i.e. de la production d'une ferme) que représente le spectre de la production agrégée.

Des estimations du spectre de la production réalisées à partir de données de production de l'ouest du Danemark sont montrées Figure 2.2. On peut y observer la diminution de la puissance du signal de production aux fréquences supérieures à 1.16×10^{-5} Hz (i.e. périodes inférieures à 24 h), pour la production agrégée de fermes situées dans un rayon de 50 km et 300 km d'une ferme de référence (graphique de gauche). L'effet de foisonnement, évalué comme dans [13] et observé sur l'ensemble du territoire, est également représenté (graphique de droite). Pour des périodes comprises entre 24 h et 30 mn, on peut voir comment la réduction de la puissance du signal de production agrégée croît linéairement avec la fréquence, et ce d'autant plus vite que la superficie du territoire couvert de fermes éoliennes augmente. Les résultats montrés ici proviennent de l'estimation, après transformation logarithmique, de la droite de régression du spectre de la production. Les estimations provenant d'un échantillon de 30 fermes de référence sélectionnées aléatoirement ont été agrégées.

L'analyse spectrale d'un signal à travers l'estimation de sa densité spectrale de puissance, ne permet pas de différencier les propriétés fréquentielles propres aux différents régimes d'un processus non-stationnaire comme peut l'être celui du vent ou de la production éolienne. Une estimation locale du spectre offre une forme de caractérisation locale de la variabilité d'un signal. Une telle forme de caractérisation a notamment été proposée dans l'étude des fluctuations de la vitesse du vent [35, 36]. En intégrant le spectre sur une plage de fréquences choisies, cette approche permet d'évaluer l'intensité des fluctuations de la vitesse du vent en chaque instant, en tenant compte des différentes composantes fréquentielles locales du signal de mesures. Qu'elle soit locale ou non l'estimation du spectre a pour but d'évaluer la présence de périodicités dans les fluctuations d'un signal. Même estimé localement le spectre d'un signal ne permet pas d'évaluer les variations d'un signal entre deux instants donnés.

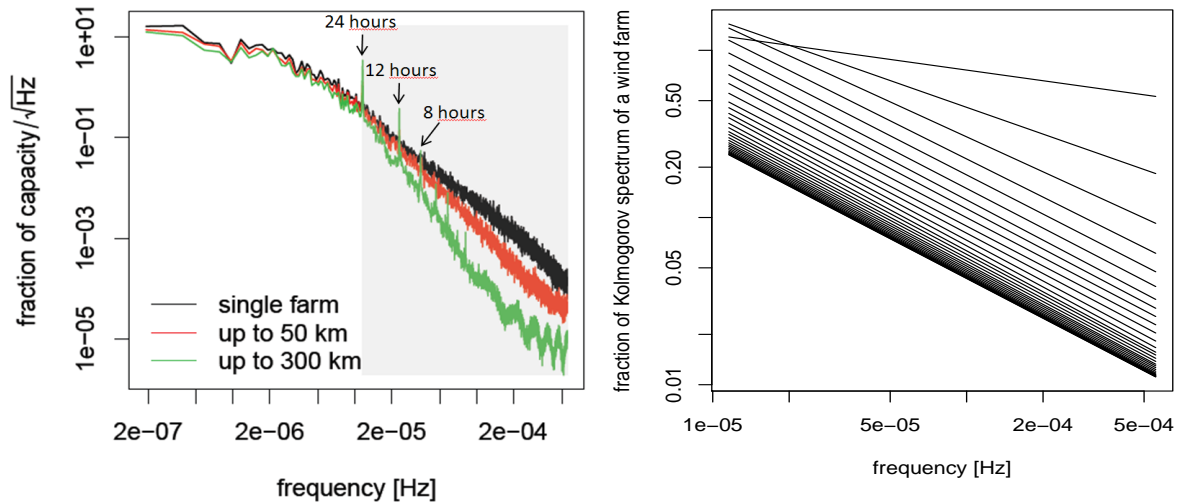


FIGURE 2.2 – Spectre de la production et effet de foisonnement – A gauche : estimations par périodogramme de la densité spectrale de puissance (représentée en échelle logarithmique) de la production agrégée pour des fermes de l’ouest du Danemark situées dans un rayon de 50 km et 300 km d’une ferme de référence. A droite : fraction du spectre de Kolmogorov représentant la réduction de la puissance du signal de production agrégée par rapport à celle d’une ferme de référence (pour des périodes comprises entre 24 h et 30 min représentées par la zone grisée sur la figure de gauche). Cette réduction croît linéairement avec la fréquence, et ce d’autant plus vite que la superficie du territoire couvert de fermes éoliennes augmente (rayon allant de 10 km autour de la ferme de référence pour la droite la plus haute à 300 km pour la plus basse).

2.2.3 Variabilité et différences finies de la production

Quand bien même il est possible d’en introduire une estimation permettant une forme de caractérisation locale de la variabilité, les outils détaillés plus haut ne permettent pas de caractériser de manière explicite les variations de la production par ce qu’elles représentent de plus élémentaire : un changement du niveau de production entre deux instants donnés. Certains travaux se sont ainsi penchés sur l’étude des variations de la production éolienne mesurées sous forme de différences finies (i.e. *step changes*), et sur les valeurs extrêmes qu’elles peuvent atteindre [13]-[18] :

$$\Delta p_t(n) = p_{t+n} - p_t,$$

où p_t désigne la production à l’instant t et n l’échelle de temps à laquelle sont mesurées les différences de niveau de production. Des mesures réalisées à partir de données de production de l’ouest du Danemark entre janvier 2006 et septembre 2009, pour des échelles de temps allant de $n = 15$ mn à $n = 5$ h, sont montrées Figure 2.3. On peut y voir comment l’amplitude maximale des variations mesurées à des échelles allant de quelques minutes à quelques

heures, peut atteindre une part importante de la capacité de production. L'effet de foisonnement ne se traduit ici que par une réduction limitée de cette amplitude. Une étude similaire réalisée à partir de données de production du réseau Texan ERCOT, a montré sous cet aspect un effet de foisonnement très supérieur. L'amplitude maximale des variations mesurées à des échelles de 30 mn et 1 h, chute de près de 50% de la capacité installée pour une production agrégée dans un rayon de seulement 200 km [13]. Dans cette étude des variations mesurées à une échelle de $n = 1$ j sont également considérées. Ces différentes échelles sont jugées pertinentes vis-à-vis des prestataires de service et des opérations sur les marchés "spot" de l'électricité. Toutefois, la différence entre les niveaux de production réalisés au même instant de la journée, à un jour d'intervalle, paraît moins révélateur que l'écart entre les niveaux de production moyens réalisés sur chacune de ces journées. La notion de lissage de la production que cela sous-entend, ramenée à des échelles de temps de quelques heures pendant lesquelles la production d'une ferme peut varier de l'ensemble de sa capacité, se rapproche des pratiques d'estimation du gradient utilisées dans la *détection des ruptures* d'un signal numérique [37].




FIGURE 2.3 – Valeurs extrêmes des différences finies de la production – Valeur maximale et 99ième percentile de la distribution des différences finies (en valeur absolue) de la production de l'ouest du Danemark entre janvier 2006 et septembre 2009. L'amplitude maximale des variations de la production peut atteindre une valeur élevée même pour des échelles de temps relativement petites (i.e. près de 70% de la capacité installée en 15 minutes). Néanmoins, l'immense majorité des variations (i.e. 99%) sont d'une amplitude bien moindre.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

Dans le but de détecter les variations brusques et importantes de la production éolienne, [38] mesurent les variations d'un signal à travers une forme de filtrage, dans laquelle ils calculent la différence f_t^{MaxMin} entre la production maximale et minimale mesurées dans une fenêtre⁵ glissante de largeur n :

$$f_t^{\text{MaxMin}} = \max_{0 \leq k \leq n} p_{t+k} - \min_{0 \leq k \leq n} p_{t+k} \quad (2.1)$$

$$= \max_{\substack{0 \leq l \leq n-1 \\ 1 \leq k \leq n-l}} \Delta p_{t+l}(k). \quad (2.2)$$

Leur approche de détection, reprise notamment dans [39], repose sur le seuillage du signal de production filtré f_t^{MaxMin} . Dès lors, la détection d'une variation brusque et importante intervient lorsque l'écart maximal entre les niveaux de production mesurés dans une fenêtre de temps (i.e. (2.2)), est supérieur à un seuil choisi.

Dans [38, 39] tout comme dans [13]-[18], la question d'un prétraitement des données (sous forme de lissage) destiné à réduire le bruit inhérent à tout signal numérique n'est pas mentionnée. Les caractéristiques du filtrage défini par l'Equation (2.1) restent inconnues. De plus, il manque dans ces travaux les raisons justifiant du choix d'échelles de temps appropriées dans la caractérisation et la détection des variations brusques et importantes de la production. Ils ne traitent pas non plus des possibilités de caractérisation qu'offre l'analyse d'une variation à différentes échelles prises *simultanément*. Dans la section suivante, nous cherchons à mieux comprendre ces différents aspects à travers une revue plus générale des techniques de détection de ruptures, décrites dans la littérature de traitement du signal.

2.3 Caractérisation et détection des ruptures d'un signal numérique

Dans la littérature de traitement du signal, les variations brusques et importantes d'un signal sont désignées sous le terme de *ruptures*. Dans cette section, nous présentons quelques notions de base propres à la détection des ruptures d'un signal numérique. La détection des ruptures d'un signal repose sur une mesure des variations de ce signal. Cette mesure est répétée continuellement le long du signal à l'aide d'une opération de filtrage. Ce filtrage a généralement pour but d'estimer le gradient du signal, et combine les opérations de lissage et de différenciation. La caractérisation des variations et la détection des ruptures d'un signal reposent ensuite sur l'étude des maxima locaux du signal filtré (en valeur absolue). Nous décrivons dans un premier temps les différentes étapes conduisant à la caractérisation des variations et à la détection des ruptures d'un signal. Nous discutons de l'influence du choix de filtre, ainsi que de celle du choix de l'échelle de temps sur la détection des ruptures d'un signal. Dans un

5. La fenêtre considérée dans (2.1) (resp. (2.2)) n'est pas centrée en t , afin de simplifier les notations. L'expression mathématique du filtrage en question n'apparaît pas dans les travaux cités et fait suite aux échanges que nous avons pu avoir avec leurs auteurs.

deuxième temps, nous nous intéressons plus particulièrement aux approches de détection reposant sur l'analyse multi-échelle d'un signal.

2.3.1 Quelques notions de base dans la détection des ruptures d'un signal numérique unidimensionnel

Lissage et différentiation d'un signal

Chercher à mesurer les variations temporelles de la production éolienne amène à prendre en compte plusieurs facteurs. Le premier est que du processus continu de production, on ne dispose que d'un signal discret de mesures. Les mesures fournies par les systèmes d'acquisition des turbines correspondent généralement à des moyennes calculées sur une base de 10 minutes. Dans un contexte de prédiction à court terme de la production, la résolution est même souvent inférieure (i.e. mesures horaires). Dès lors, il est courant d'estimer la dérivée d'un signal continu à l'aide de différences finies [40]. C'est notamment le cas dans la littérature éolienne [13]-[18].

Dans les travaux relatifs à la littérature éolienne, il n'est pas fait usage d'aucune forme de lissage du signal de production préalablement au calcul des différences finies. Selon [41], une forme de lissage doit pourtant être systématiquement pratiquée dans le but d'atténuer le bruit présent dans un signal numérique et ainsi, de régulariser l'opération de différentiation. Bien souvent l'opération de lissage d'un signal numérique prend la forme d'un calcul de moyenne mobile, autrement dit d'un filtrage linéaire, au moyen d'un filtre h dont on calcule le produit de convolution f avec le signal (d'autres formes de lissage, i.e. reposant sur un filtrage non linéaire, peuvent être trouvées dans la littérature, e.g. filtrage médian [42]). Un calcul simple permet alors de montrer que l'ordre dans lequel les opérations de lissage et de différentiation sont conduites n'influe pas sur le résultat de l'estimation de la dérivée $f = \Delta f$. Ainsi, l'estimation de la dérivée d'un signal comme celle du signal de production p , repose sur une seule et unique opération de filtrage, au moyen d'un filtre dit *dérivateur* h :

$$f = \Delta f = \Delta(p * h) = p * \Delta h = p * h.$$

Parmi les filtres dérivateurs les plus connus, on peut citer les filtres de Sobel [43] et Prewitt [44]. L'opération de lissage de ce dernier repose sur le calcul d'une moyenne mobile équilibrée d'ordre fini. Dans le cas unidimensionnel, le filtre de Prewitt de largeur $2n + 1$ est, à une constante de normalisation près :

$$h = 1/n \times \underbrace{[1 \dots 1]}_n \ 0 \ \underbrace{[-1 \dots -1]}_n. \quad (2.3)$$

La valeur à un instant t du signal de production différentié au moyen du filtre défini ci-dessus, correspond ainsi à la différence entre les niveaux de production moyens (calculés à partir de n mesures consécutives de production) de part et d'autre de l'instant t :

$$\begin{aligned}
 f_t &= (p * h)_t \\
 &= \sum_{k=-n}^n p_{t-k} h_k \\
 &= \frac{1}{n} \sum_{k=1}^n p_{t+k} - \frac{1}{n} \sum_{k=1}^n p_{t-k}.
 \end{aligned}$$

La forme très générale que l'on peut donner à un filtre de lissage, e.g. issu d'une fonction positive et d'intégrale égale à 1, fait qu'il est possible d'envisager beaucoup de formes différentes pour un filtre dérivateur. Un exemple classique [45] est celui de la dérivée première d'une Gaussienne, filtre dérivateur basé sur un lissage du même nom :

$$h(t) = -K \frac{t}{\sqrt{2\pi}s^3} e^{-\frac{t^2}{2s^2}}, \quad (2.4)$$

où s est un paramètre définissant le degré de lissage, et K est une constante de normalisation. Une valeur de $K = \sqrt{2\pi}s$ permet de conserver les unités de mesure. Le calcul de $(p * h)_t$ correspond encore à la différence entre les niveaux moyens de p de part et d'autre de t , en considérant cette fois une moyenne pondérée d'ordre infini.

Réponse d'un filtre dérivateur, caractérisation d'une variation et détection des ruptures d'un signal

La réponse d'un filtre dérivateur à une variation dépend du degré de lissage opéré par le filtre, vis-à-vis de l'échelle de temps de la variation. Nous discutons de l'influence du *paramètre d'échelle* d'un filtre (i.e. resp. n et s dans les Equations (2.3) et (2.4)), sur la mesure des variations et la détection des ruptures d'un signal un peu plus loin. Généralement, la mesure d'une variation d'un signal fait apparaître un maximum local dans la réponse en valeur absolue du filtre. Ce maximum permet de caractériser une variation. La position du maximum offre un repère temporel permettant de localiser une variation à partir d'un point central de sa géométrie (i.e. un point d'inflexion, voir Figure 2.4). Nous désignerons la position de ce point t_I comme l'*instant d'apparition* d'une variation. Parallèlement, la valeur du maximum permet de définir une notion d'*intensité* I , quantifiant le caractère brusque et l'amplitude d'une variation. L'introduction d'un seuil permet de définir l'intensité minimale pour laquelle une variation est jugée comme brusque et importante. Dans la Figure 2.4, on peut voir un schéma illustratif de la procédure de détection d'une rupture. Les caractéristiques d'une variation et la procédure de seuillage que nous venons de décrire y sont représentées à travers un exemple de rupture observé dans un épisode de production de 48 h d'une ferme éolienne.

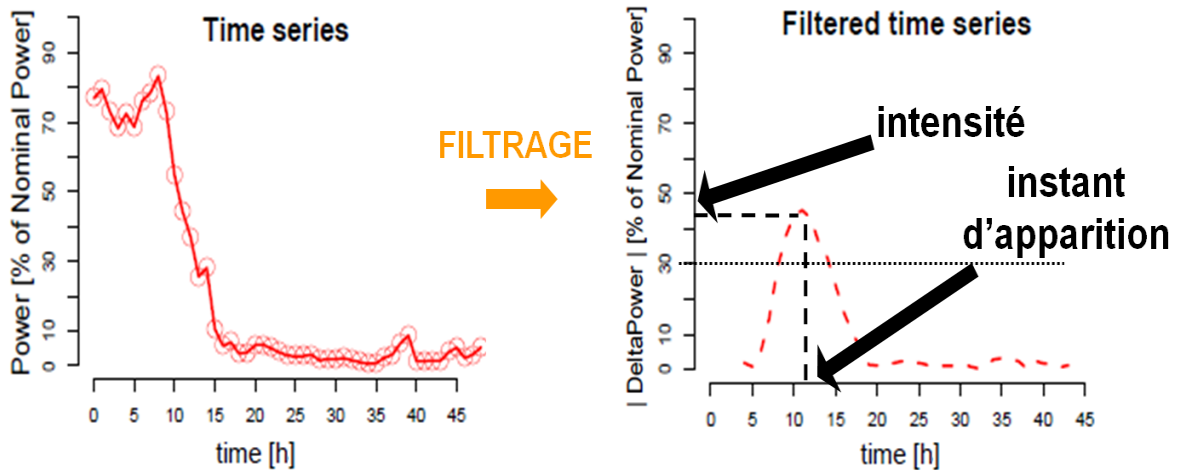


FIGURE 2.4 – Caractérisation d’une variation, seuillage et détection d’une rupture – Schéma représentant la réponse d’un filtre dérivateur à une variation. La présence d’une variation dans le signal fait apparaître un maximum local dans le module de la réponse du filtre. La position et la valeur de ce maximum définissent un repère temporel (l’instant d’apparition d’une variation), et une mesure combinée du caractère brusque et de l’amplitude d’une variation (son intensité). Ces paramètres caractérisent une variation. L’introduction d’un seuil (graphique de droite, droite horizontale en pointillée) permet de définir l’intensité minimale pour laquelle une variation est jugée comme brusque et importante.

Forme d’un filtre et détection des ruptures d’un signal

L’approche classique dans la détection des ruptures d’un signal repose, comme nous venons de la décrire, sur le seuillage de la dérivée (en valeur absolue) de ce signal. Il est alors important d’assurer une estimation satisfaisante de la dérivée du signal en question. Certains filtres sont ainsi conçus dans le seul but d’optimiser l’estimation du gradient d’un signal continu, à partir d’une version discrète de ce signal (on pourra voir entre autres ([40, 46, 47])). Toutefois, la conception d’un filtre dédié à la détection des ruptures d’un signal devrait être réalisée avec pour objectif d’optimiser cette détection, et ce d’après l’idée que l’on se fait d’une rupture. Canny [48] fut le premier à introduire un nouveau paradigme, dans lequel le problème de détection est explicitement formulé à partir d’un modèle décrivant la géométrie d’une rupture, et de critères d’évaluation. Ces derniers, tels qu’initialement énoncés par Canny, se présentent sous la forme suivante :

- **Critère de détection :** Il est fondé sur le souhait de maximiser la réponse du filtre à la rupture vis-à-vis de la réponse du filtre au bruit, et résulte du calcul du ratio signal-sur-bruit en sortie du filtre (SNR). Pour une rupture modélisée par la fonction R , centrée en 0, le ratio SNR correspond au quotient de la réponse du filtre h à R en 0 (en valeur absolue), avec l’écart-type de la réponse du filtre au bruit. Pour un filtre h supposé de

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

support fini, ce ratio s'écrit :

$$\text{SNR} = \frac{|R * h(0)|}{\sigma \|h\|_2},$$

où σ désigne l'écart-type du bruit (e.g. blanc Gaussien) dans lequel se trouve immergée la rupture R , et $\|\cdot\|_2$ désigne la norme euclidienne.

- **Critère de localisation** : Il s'agit ici de quantifier l'incertitude associée à l'estimation de la position du centre de la rupture. Le second critère que l'on cherche à maximiser repose alors sur le calcul de (l'inverse de) l'écart-type de cette estimation, et s'écrit :

$$\text{Loc} = \frac{|R' * h'(0)|}{\sigma \|h'\|_2},$$

où $'$ symbolise l'opération de différentiation.

- **Faible multiplicité des réponses** : Selon les deux premiers critères énoncés ci-dessus, le filtre optimal de détection de support fini est de forme symétrique à celle de la rupture. Le filtre de Prewitt (2.3) (encore appelé *difference of boxes edge detector*) constitue ainsi, toujours selon ces deux critères, le filtre de support fini optimal dans la détection des ruptures en forme de *step* (i.e. définies par la fonction de Heaviside : $R(t) = 1$ si $t \geq 0$, 0 sinon). Toutefois, la réponse d'un tel filtre à un step bruité peut présenter plusieurs maxima proches dont il est difficile de distinguer, au milieu des réminiscences dues au bruit, lequel localise la rupture. Une contrainte supplémentaire dans la détermination d'un filtre optimal consiste ainsi à limiter le nombre N_b de maxima dus au bruit dans la région où se concentre la réponse du filtre à la rupture. Ce nombre N_b peut alors s'écrire :

$$N_b = \frac{2}{k},$$

où k est la fraction que représente la distance entre deux maxima consécutifs dans la réponse du filtre à la rupture bruitée par rapport à la largeur du filtre.

Canny définit finalement le filtre optimal h_{opt} dans la détection des ruptures modélisées par R et immergées dans un bruit blanc Gaussien, comme la solution du problème d'optimisation suivant :

$$h_{\text{opt}} = \underset{\text{s.c. } N_b=2/k}{\text{argmax}} \text{SNR} \times \text{Loc}.$$

Certaines des hypothèses sur lesquelles repose la formulation des critères proposés par Canny ont été critiquées [49, 50] (e.g. dérivabilité du filtre et du signal dans l'expression du critère de localisation). Pour éviter la nature mal posée du problème de différentiation, mais aussi parce qu'en pratique l'application et l'évaluation d'un filtre ont toujours lieu sur des

signaux discrets, [50] ont proposé une reformulation de ces critères dans un contexte discret. Ils ont notamment prouvé que l'optimalité d'un filtre dans un contexte continu n'était pas nécessairement préservée dans un contexte discret.

Dans la littérature de traitement du signal, le terme de ruptures cache une multitude de formes qui peuvent être observées dans un signal et dont une rupture simple, comme un step, constitue une composante élémentaire. La succession de deux steps de sens contraire, séparés par un plateau, donne naissance à une crête (appelée aussi *ridge*), celle de deux segments inclinés à une forme de toit (i.e. *roof*). La forme très générale donnée par Canny au problème de détection des ruptures prend en considération la possibilité de chercher à concevoir des filtres capables de détecter différentes formes de rupture (il traite d'ailleurs des deux formes citées plus haut). Bien sûr, la résolution mathématique du problème d'optimisation conduisant à la définition d'un filtre optimal se complexifie dès lors que l'on cherche à détecter des formes plus élaborées. Si l'approche de Canny permet de rechercher une solution approximative pour divers types de rupture, lui-même se limite à ne donner une solution exacte qu'au cas d'un simple step. La recherche d'une solution exacte pour des modèles de rupture plus complexes a fait l'objet d'autres travaux. Modélisant une (unique) rupture et sa pente à l'aide d'une famille paramétrée d'exponentielles, [51] ont ainsi décrit une classe de filtres optimaux (au sens de Canny) dans la détection de variations plus ou moins brusques d'un signal.

Largeur d'un filtre et détection des ruptures d'un signal

Le paramètre d'échelle d'un filtre s'identifie à l'échelle des variations que l'on cherche à mesurer. Ce paramètre contrôle la largeur du filtre, dès lors qu'il s'agit d'un filtre de support fini (e.g. n dans l'Equation (2.3)), plus généralement son "étalement" dans le cas d'un filtre de support infini (e.g. s dans l'Equation (2.4)). Fixer sa valeur établit une distinction entre les variations que l'on cherche à mesurer, et les variations identifiées au bruit. Dans le cas d'une rupture isolée, la détection et la localisation de cette dernière bénéficient d'une meilleure atténuation du bruit lorsqu'est employée une plus grande "largeur" de filtre. Cependant, accroître la largeur du filtre vient à terme perturber la détection d'une rupture, notamment du fait de la présence de ruptures voisines dans le support du filtre (voir Figure 2.5). Choisir une échelle de détection appropriée relève donc principalement de la bonne gestion du compromis qu'il y a à vouloir d'une part, atténuer le bruit dans un signal, et de l'autre, limiter les interactions dans la détection de ruptures proches.

Dans certains travaux, la détermination d'un filtre optimal de détection repose sur une modélisation où la proximité de deux ruptures consécutives est représentée de manière explicite [52, 53]. La largeur du filtre optimal est alors égale à la valeur du paramètre représentant la distance séparant ces deux ruptures. Cette dernière varie généralement dans un signal. Sa prise en compte dans l'élaboration d'un filtre de détection ne permet donc pas de se départir d'un processus de sélection d'une (ou plusieurs) échelle de détection appropriée. Les questions que soulève le choix d'échelle(s) dans la caractérisation des variations et la détection des ruptures d'un signal sont nombreuses. Elles sont traitées de manière plus exhaustive




FIGURE 2.5 – Choix d'échelle et réponse d'un filtre dérivateur à des ruptures proches – En noir : signal de production éolienne simulé avec des ruptures bruitées de même amplitude (80% de la valeur de production nominale P_n), et de même durée (10 mn), plus ou moins proches les unes des autres. La résolution temporelle est de 10 mn. En rouge : réponse en valeur absolue de la dérivée première d'une Gaussienne, avec une valeur de paramètre d'échelle de $s = 10$ mn. En vert : réponse en valeur absolue du même filtre avec une valeur de paramètre d'échelle de $s = 1$ h. Pour une grande valeur de s , la réduction du bruit permet de mieux localiser une rupture lorsque celle-ci est suffisamment "isolée" (e.g. 3ème et 4ème ruptures en partant de la gauche). Lorsque deux ruptures sont proches et se retrouvent simultanément dans le support du filtre (e.g. deux premières ruptures), leur localisation peut s'en trouver erronée, et la réponse du filtre atténuée.

dans la sous-section suivante.

2.3.2 Caractérisation multi-échelle et détection des ruptures d'un signal

Dans la première partie de cette section, nous avons discuté d'une caractérisation permettant de décrire une variation à une échelle donnée. Nous discutons maintenant d'approches permettant une description plus exhaustive à partir du filtrage d'une variation à différentes échelles. Nous expliquons en quoi l'analyse à différentes échelles d'une variation

permet d'en décrire certains paramètres géométriques. Nous décrivons également comment à partir d'une caractérisation multi-échelle, il est possible de développer de nouvelles approches de détection de ruptures.

Analyse multi-échelle et normalisation

Afin de pouvoir comparer les mesures d'une variation à différentes échelles, il est souhaitable d'effectuer une normalisation appropriée. Une normalisation fréquemment rencontrée est celle introduite à travers l'*analyse par ondelettes* [54, 55]. L'analyse par ondelettes consiste à analyser un signal à différentes échelles s , en filtrant ce dernier à partir d'une famille de fonctions $(\psi_s)_s$. Ces dernières sont toutes issues de la dilatation d'une même fonction centrée et de moyenne nulle ψ , appelée ondelette mère. On définit ainsi la transformée en ondelettes continue $Wp(t, s)$ d'un signal p par :

$$\begin{aligned} Wp(t, s) &= (p * \psi_s)(t), \\ \psi_s(t) &= K \bar{\psi}\left(-\frac{t}{s}\right), \end{aligned}$$

où $\bar{\psi}$ désigne la conjuguée complexe de ψ . La transformation en ondelettes est caractérisée par la constante de normalisation K , définie de manière à conserver une norme euclidienne égale à 1 quelque soit l'échelle s , i.e.

$$\begin{aligned} \|\psi\|_2 &= 1, \\ \|\psi_s\|_2 = 1 &\Rightarrow K = \frac{1}{\sqrt{s}}. \end{aligned}$$

La transformée en ondelettes continue permet une analyse locale des propriétés d'un signal. Le choix de l'ondelette mère dépend des propriétés du signal que l'on cherche à étudier (e.g. estimation locale du spectre). Dans la caractérisation et la détection des ruptures d'un signal, on privilégie ainsi souvent l'utilisation d'une ondelette réelle [54, 55]. La dérivée première d'une Gaussienne définit par exemple une famille d'ondelettes de la manière suivante :

$$\begin{aligned} \psi(t) &= \sqrt{\frac{2}{\sqrt{\pi}}} t e^{-\frac{t^2}{2}}, \\ \psi_s(t) &= -\sqrt{\frac{2}{\sqrt{\pi}}} \frac{t}{s\sqrt{s}} e^{-\frac{t^2}{2s^2}}. \end{aligned}$$

Bien que la transformée en ondelettes soit souvent utilisée, certains travaux propres à la détection des ruptures à partir de l'analyse multi-échelle d'un signal, font état d'autres formes de normalisation (on pourra voir par exemple [56, 57]).




FIGURE 2.6 – Mesure des variations d'un signal de production par transformée en ondelettes – *En bas : épisode de production d'environ 1 semaine d'une ferme éolienne Française de puissance nominale $P_n = 8$ MW. Les mesures de production sont échantillonnées toutes les 10 mn. Elles sont représentées ici après avoir été normalisées par la valeur de production nominale P_n de la ferme. En haut : module de la transformée en ondelettes continu mesurant les variations du signal de production. Cette dernière a été calculée à partir de la dérivée première d'une Gaussienne, pour des valeurs d'échelles allant de 10 mn à 3 h par pas de 10/3 mn. Les mesures proches de 0 sont représentées en rouge, alors que les mesures les plus grandes sont représentées en blanc.*

Différentes formes de caractérisation

L'analyse multi-échelle d'un signal peut conduire à différentes formes de caractérisation de ses ruptures, ou plus généralement de ses variations. Dans certains travaux, cette caractérisation repose sur la définition d'une mesure des variations d'un signal, issue de la combinaison des réponses d'un filtre à différentes échelles [58, 59]. Cette combinaison est effectuée à chaque instant, indépendamment des réponses du filtre aux instants précédents et futurs. En considérant un filtrage reposant sur un filtre h_s , où s désigne l'échelle, la mesure des variations d'un signal à un instant t , combine les mesures effectuées à différentes échelles $s_1 < \dots < s_n$ de la manière suivante :

Caractérisation de la variabilité de la production éolienne

$$f_t = K \odot_{i=1}^n (h_{s_i} * p)_t, \quad (2.5)$$

où p désigne le signal (de production), et n le nombre d'échelles. Le symbole \odot désigne l'opération algébrique choisie pour combiner les informations recueillies à différentes échelles. La constante K est une constante de normalisation appropriée vis-à-vis de l'opération \odot . Dans [58], \odot désigne une somme, et $K = 1/\max |\sum_i (h_{s_i} * p)_t|$. La mesure d'une variation à un instant donné s'exprime alors relativement à une valeur maximale mesurée dans un signal. On peut lui préférer $K = 1/n$. A chaque instant, une variation est alors mesurée de manière absolue. On peut envisager d'autres mesures en considérant des combinaisons basées sur d'autres opérations algébriques. On peut par exemple considérer le cas où \odot désigne un produit [59]. Poser $K = 1$, et remplacer f_t par f_t^{norm} en posant $f_t^{\text{norm}} = \text{sign}[(h_{s_n} * p)_t] \cdot |f_t|^{1/n}$, permet alors de conserver les unités de mesure.

Généralement, la position des maxima caractérisant l'instant d'apparition t_I d'une variation diffère d'une échelle à l'autre. Il n'est pas sûr a priori que la combinaison f_t définie par l'Equation (2.5), effectuée sans alignement préalable des signaux $(h_{s_i} * p)_t$, préserve ces maxima. Plus généralement, il n'est pas sûr qu'une telle mesure offre une caractérisation satisfaisante des variations d'un signal. Dans [58], son adéquation dans la caractérisation des ruptures d'un signal de production éolienne, est évaluée à partir de l'étude de résultats expérimentaux. La valeur de s_1 et le pas d'incrément de l'échelle y sont fixés, égaux à la résolution des signaux, tandis que l'influence de s_n est étudiée à partir d'exemples types. Les performances théoriques d'une approche de détection basée sur la mesure définie Equation (2.5), où \odot désigne un produit, ont été étudiées dans [59]. Néanmoins, cette étude se limite au cas de la détection d'une rupture isolée, à partir de la combinaison d'informations recueillies à seulement deux échelles différentes.

L'ensemble des maxima définissant les intensités et les instants d'apparition d'une variation à différentes échelles : $\{(I(s), t_I(s)), 0 < s \leq s_{\max}\}$, représente en soi une forme de caractérisation. Cette dernière n'est définie que si un maximum local associé à une variation dans le signal dérivé (en valeur absolue), existe pour toutes valeurs d'échelle inférieures à une échelle maximale $s_{\max} \leq s_n$. La dérivée d'une Gaussienne autorise une telle forme de caractérisation (voir Figure 2.7), contrairement aux filtres de Prewitt (Equation (2.3)), et "MaxMin" (Equation (2.1)). De manière plus générale, l'existence d'une telle caractérisation s'apparente à la propriété dite de *causalité* dans la littérature traitant des représentations temps-échelle d'un signal [60, 61]. La propriété de causalité veut que certains des éléments décrivant la structure d'un signal disparaissent à mesure que l'échelle se fait plus grossière, pour ne laisser que ceux en offrant une représentation plus synthétique. Selon certains travaux, le noyau Gaussien est probablement le seul parmi une large classe d'opérateurs, à offrir cette propriété [61, 62].

Une autre forme de caractérisation réside dans l'estimation de paramètres (amplitude, durée, etc), définissant un modèle de rupture. Les ruptures d'un signal peuvent être identifiées à des singularités, i.e. à des absences locales de régularité (e.g. step, dirac). Dans [63], les

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

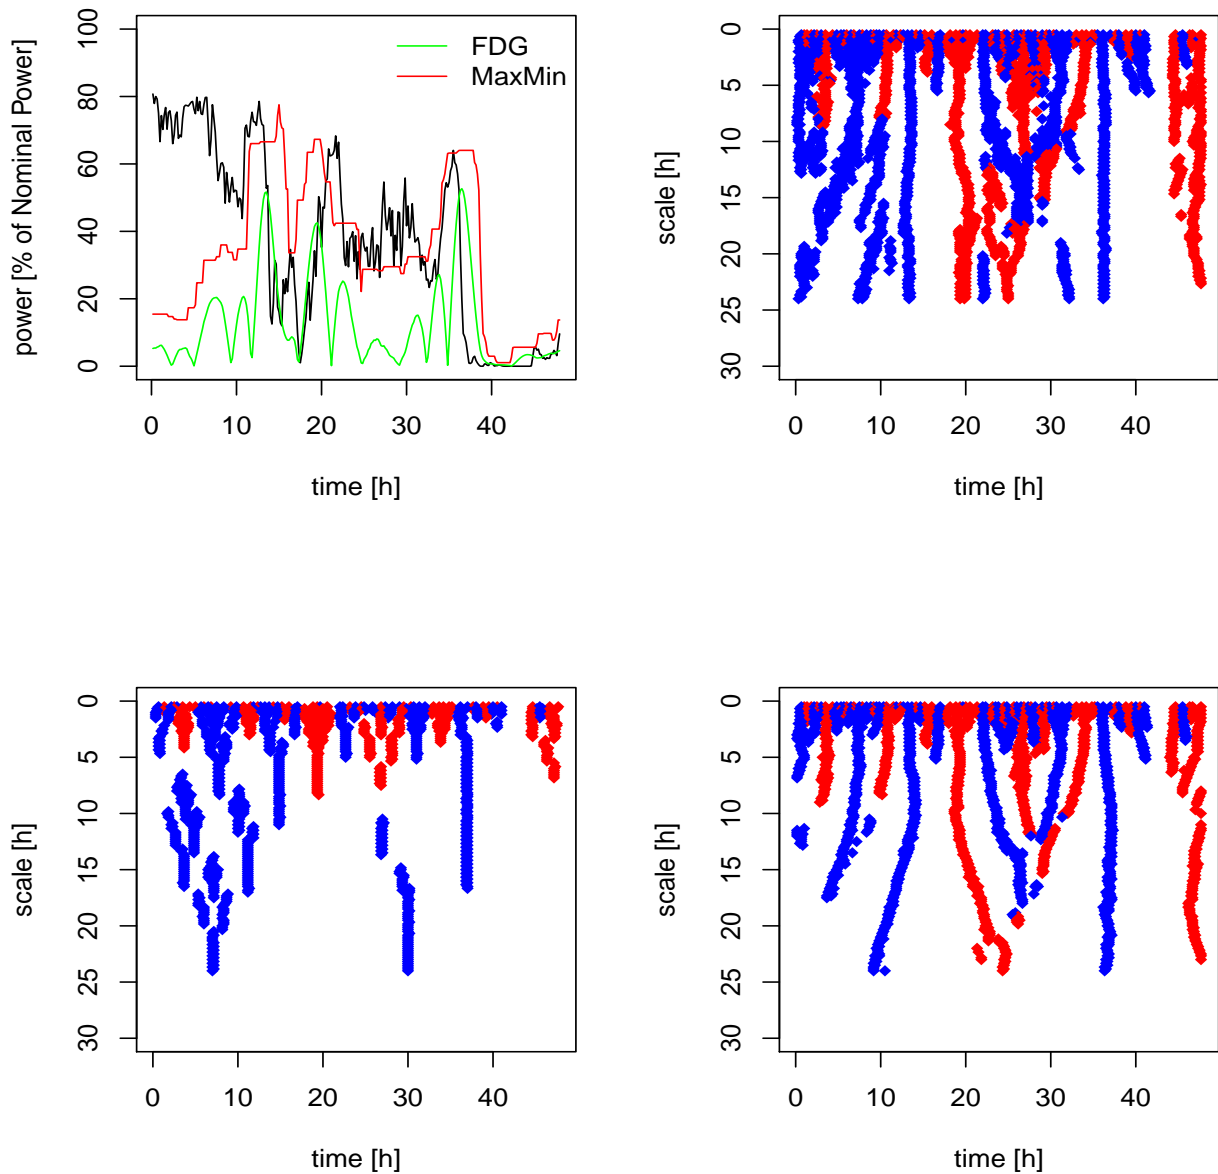


FIGURE 2.7 – Filtres dérivateurs et causalité – En haut à gauche : exemple d'un épisode de production de 48 h d'une ferme Française de 8 MW (courbe noire). Les courbes verte et rouge représentent la valeur absolue du signal de production filtré, respectivement à l'aide de la dérivée première d'une Gaussienne (FDG, $s = 5/6$ h), et du filtre défini Equation (2.1) (MaxMin, $n = 5$ h). Les autres figures représentent la position des maxima du module du signal de production filtré à différentes échelles : avec le filtre de Prewitt (figure en haut à droite), MaxMin (en bas à gauche) et FDG (en bas à droite). Les largeurs de filtre considérées ici s'étendent de 20 mn à 24 h (resp. $s = 20/6$ mn à 4 h pour le filtre FDG), avec un pas d'incrément de 10 mn (resp. $\Delta s = 10/6$ mn). En rouge sont représentés les instants d'apparition des variations croissantes, et en bleu ceux des variations décroissantes.

ruptures d'un signal sont modélisées sous la forme de singularités isolées, lissées. De la caractérisation mathématique des singularités d'un signal à partir de sa transformée en ondelettes continue [64] (on pourra voir aussi [61, 65]), ils déduisent l'inégalité suivante :

$$|Wp(t, s)| \leq A.s.s_0^{\alpha-1}, \text{ où } s_0 = \sqrt{s^2 + b^2}, \quad (2.6)$$

où A désigne l'amplitude de la rupture, α l'ordre de régularité Lipschitzienne caractéristique du type de singularité, et b désigne l'écart-type d'un noyau Gaussien à partir duquel est lissé la singularité. Ce paramètre représente le caractère plus ou moins brusque d'une rupture. Exploitant la propriété de causalité de l'ondelette Gaussienne, ils développent un algorithme visant à estimer les paramètres A , α et b , à partir de la valeur des maxima d'ondelettes. Leur approche a notamment été reprise dans le développement d'un algorithme de caractérisation et de détection des ruptures dans une image [66]. Dans cet algorithme, différents types de singularité définissant différents modèles de rupture sont considérés a priori. La valeur des maxima d'ondelettes en réponse à chaque modèle est calculée en fonction du paramètre d'échelle (voir l'exemple 1D donné Figure 2.8). Une transformation permet ensuite d'estimer les paramètres d'une rupture, à partir d'un modèle de régression linéaire simple. Les ruptures d'une image sont finalement classifiées suivant le modèle offrant la meilleure adéquation.

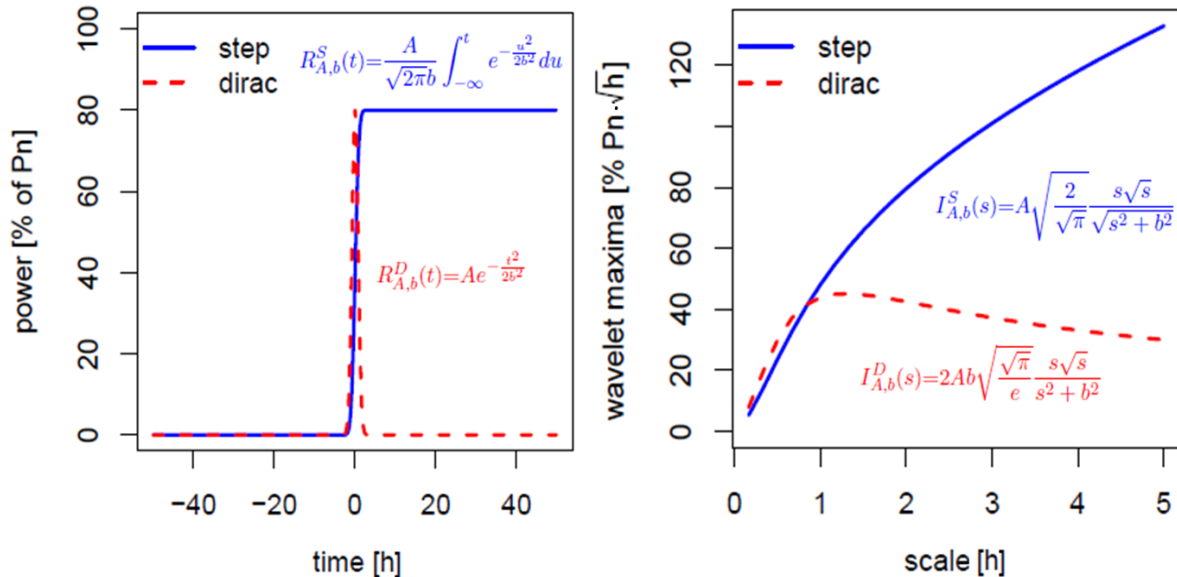


FIGURE 2.8 – Modèles de rupture et caractérisation multi-échelle – A gauche : modèles de rupture issus de différents types de singularité : un step (en bleu), et un dirac (en rouge). Les ruptures représentées ici sont d'amplitude $A = 80\% P_n$, et ont été lissées avec un noyau Gaussien d'écart-type $b = 3/4$ h. A droite : maxima d'ondelettes issus d'une ondelette Gaussienne, représentant l'intensité des ruptures montrées à gauche en fonction du paramètre d'échelle s .

Procédures locales de sélection d'échelle et détection des ruptures d'un signal

La sélection d'une ou plusieurs échelles appropriées dans la détection des ruptures d'un signal, tient du compromis entre l'atténuation du bruit, et la limitation des interactions dans la détection de ruptures proches. La gestion de ce compromis amène à des procédures de sélection d'échelle(s) qui dépendent à la fois des caractéristiques du signal étudié, et de la caractérisation d'une rupture. Dans un signal où la durée séparant deux ruptures consécutives est plus ou moins constante, la gestion de ce compromis peut être globale, et ne nécessiter la sélection que d'une seule et même échelle globalement optimale. La détermination de cette échelle peut se faire à travers la conception d'un filtre optimisant la détection d'une géométrie de rupture, dans laquelle est modélisée la durée *fixe* séparant deux ruptures consécutives [52, 53].

Bien souvent, la durée séparant deux ruptures consécutives dans un signal varie. La bonne détection de l'ensemble des ruptures d'un signal nécessite d'avoir recours à une procédure locale de sélection d'échelle (ou à une procédure basée sur la combinaison de plusieurs échelles comme dans [58, 59]). Dans [67], cette procédure repose sur le calcul d'une valeur critique f_c , définissant la valeur minimale de la réponse en valeur absolue d'un filtre (la dérivée première d'une Gaussienne), assurant de manière *localement fiable* la présence d'une rupture dans une image :

$$f_c(s) = \frac{\sigma}{2\sqrt{2\pi}s^2} \sqrt{-2 \ln(\alpha_{loc})},$$
$$\alpha_{loc} = 1 - (1 - \alpha)^{1/n},$$

où σ désigne l'écart-type d'un bruit blanc Gaussien, et s le paramètre d'échelle du filtre. La valeur de $f_c(s)$ correspond au $1 - \alpha_{loc}$ quantile de la distribution de la réponse en valeur absolue et à l'échelle s , de la dérivée première d'une Gaussienne au bruit. Le niveau de significativité local α_{loc} représente la probabilité de désigner à tort un pixel comme appartenant à une rupture. Il est choisi à partir d'un niveau de significativité global α , dans une image comportant n pixels. Le calcul de la réponse du filtre $f(s)$ à une rupture modélisée par un step lissé, permet de prouver l'existence d'une échelle minimale *localement fiable* s_{loc} , pour laquelle cette réponse est supérieure (en valeur absolue) à la valeur critique :

$$s_{loc} = \min\{s, |f(s)| > f_c(s)\}.$$

L'existence de l'échelle s_{loc} , permet de s'assurer de manière localement fiable que la détection d'une rupture n'est pas un artefact dû au bruit. Son utilisation permet de limiter les interactions dans la détection de ruptures proches. C'est un des avantages de cette approche, dont le développement ne nécessite pas la modélisation de la proximité de deux ruptures.

La sélection locale d'une échelle peut faire suite à l'estimation des paramètres d'un modèle de rupture. Dans [66], l'échelle de localisation d'une rupture est ainsi définie à partir de

l'estimation \hat{b} du paramètre de lissage b d'une singularité (voir Equation (2.6) et Figure 2.8) :

$$s_{\text{loc}} = \kappa \cdot \hat{b}.$$

Sur la base d'une analyse de sensibilité au bruit réalisée à partir de simulations, [66] recommande l'utilisation d'une valeur de κ comprise entre 0 et 2. Cette valeur dépend aussi vraisemblablement de la géométrie de rupture considérée, et de la proximité de deux ruptures consécutives. L'exemple d'un dirac Figure 2.8 (représentatif d'une proximité immédiate), révèle une valeur de $\kappa = \sqrt{3}$ maximisant (en valeur absolue) l'intensité de chacune des ruptures de sens contraires constituant la géométrie du modèle. La valeur associée du paramètre d'échelle est la plus grande valeur d'échelle pour laquelle la réponse du filtre à chacune des deux ruptures ne s'altèrent pas l'une l'autre. On peut voir à travers cet exemple, l'indication plus générale qu'un changement dans l'évolution à travers les échelles de l'intensité d'une rupture, rend compte de l'entrée potentielle d'une seconde rupture de sens contraire dans le support d'un filtre. L'échelle associée à la valeur d'intensité maximale d'une rupture (en valeur absolue et pourvu qu'on utilise un filtre causal) :

$$s_{\text{loc}} = \underset{0 < s \leq s_{\text{max}}}{\operatorname{argmax}} |I(s)|, \quad (2.7)$$

constitue ainsi un choix permettant de gérer localement le compromis entre atténuation du bruit, et limitation des interactions dans la détection de ruptures proches. L'utilisation d'une telle procédure de sélection d'échelle a notamment été suggérée dans [56].

2.4 Conclusions

L'augmentation des taux de pénétration de l'éolien dans les systèmes électriques est responsable d'une plus grande exposition de ces derniers au caractère intermittent de la production, et à la nature aléatoire de ses variations. La volonté d'accroître les capacités de production éolienne pose la question de savoir si les moyens de production conventionnels sont à même de fournir une flexibilité suffisante pour gérer efficacement, et de manière sûre, l'équilibre d'un système. En ce sens, il est important de connaître les caractéristiques des variations de la production éolienne (amplitude, vitesse de variation, etc), en association avec celles de la demande, et des moyens de production conventionnels (e.g. caractéristiques de modulation de la production).

Aujourd'hui, les méthodes de la littérature dédiées à l'étude des variations de la production éolienne ne sont généralement pas destinées à fournir une estimation des caractéristiques en question. Ces méthodes sont plutôt axées sur l'évaluation des saisonnalités du processus de production à travers l'estimation de la périodicité de ses variations, ou encore sur l'évaluation du caractère volatil du processus de production.

L'évaluation du caractère brusque et important des variations de la production éolienne

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

nécessite de mesurer ces dernières à partir d'une forme d'estimation de la dérivée des signaux de production. La majorité des approches présentes dans la littérature éolienne néglige certains aspects importants vis-à-vis de cette estimation. Pour mieux comprendre ces aspects, nous avons présenté dans ce chapitre un état de l'art des approches de caractérisation et de détection des ruptures d'un signal numérique.

Bien souvent, les performances de ces approches ont été évaluées à partir de modèles de rupture, dont les hypothèses ne reflètent pas correctement les caractéristiques d'un signal issu de données réelles. En ce sens, le processus de production éolienne présente certaines caractéristiques (e.g. processus borné et non-stationnaire), vis-à-vis desquelles il serait intéressant d'évaluer le comportement de ces approches. Leur étude à partir de simulations provenant d'un modèle de rupture intégrant ces caractéristiques, pourrait permettre de définir une approche appropriée dans la caractérisation et la détection des variations brusques et importantes de la production éolienne. La proposition d'un modèle de rupture adapté, et l'étude paramétrique d'approches de détection constituent l'objet du chapitre suivant.

Bibliographie

- [1] J. Apt. The spectrum of power from wind turbines. *Journal of Power Sources*, 169(2) :369 – 374, 2007.
- [2] L. Ran, J.R. Bumby, and P.J. Tavner. Use of turbine inertia for power smoothing of wind turbines with a DFIG. In *Harmonics and Quality of Power, 2004. 11th International Conference on*, pages 106 – 111, sept. 2004.
- [3] M. Tsili and S. Papathanassiou. A review of grid code technical requirements for wind farms. *Renewable Power Generation, IET*, 3(3) :308 –332, sept. 2009.
- [4] N. Boccard. Capacity factor of wind power realized values vs. estimates. *Energy Policy*, 37(7) :2679 – 2688, 2009.
- [5] S.C. Pryor, R.J. Barthelmie, and J.T. Schoof. The impact of non-stationarities in the climate system on the definition of "a normal wind year" : a case study from the Baltic. *International Journal of Climatology*, 25(6) :735–752, 2005.
- [6] H.Aa. Nielsen, T.S. Nielsen, A.K. Joensen, H. Madsen, and J. Holst. Tracking time-varying-coefficient functions. *International Journal of Adaptive Control and Signal Processing*, 14(8) :813–828, 2000.
- [7] I. Sánchez. Short-term prediction of wind energy production. *International Journal of Forecasting*, 22(1) :43 – 56, 2006.
- [8] P. Pinson, H.Aa. Nielsen, H. Madsen, and T.S. Nielsen. Local linear regression with adaptive orthogonal fitting for the wind power application. *Statistics and Computing*, 18 :59–71, 2008.
- [9] J.K. Moller, H.Aa. Nielsen, and H. Madsen. Time-adaptive quantile regression. *Computational Statistics & Data Analysis*, 52(3) :1292 – 1303, 2008.
- [10] Y.H. Wan and B.K. Parsons. Factors relevant to utility integration of intermittent renewable technologies. Technical report, National Renewable Energy Laboratory, U.S. Department of Energy. [Available online : <http://www.nrel.gov/docs/legosti/old/4953.pdf>], 1993.
- [11] F.D. Galiana, F. Bouffard, J.M. Arroyo, and J.F. Restrepo. Scheduling and pricing of coupled energy and primary, secondary, and tertiary reserves. *Proceedings of the IEEE*, 93(11) :1970 –1983, nov. 2005.
- [12] J. Kiviluoma, M. O'Malley, A. Tuohy, P. Meibom, M. Milligan, B. Lange, H. Holttinen, and M. Gibescu. Impact of wind power on the unit commitment, operating reserves, and market design. In *Power and Energy Society General Meeting, 2011 IEEE*, pages 1 –8, july 2011.
- [13] W. Katzenstein, E. Fertig, and J. Apt. The variability of interconnected wind plants. *Energy Policy*, 38(8) :4400 – 4410, 2010.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

- [14] E. Ela and J. Kemper. Wind plant ramping behavior. Technical report, National Renewable Energy Laboratory, U.S. Department of Energy. [Available online : <http://www.nrel.gov/docs/fy10osti/46938.pdf>], 2009.
- [15] Y.H. Wan. Analysis of wind power ramping behavior in ERCOT. Technical report, National Renewable Energy Laboratory, U.S. Department of Energy. [Available online : <http://www.nrel.gov/docs/fy11osti/49218.pdf>], 2011.
- [16] Y.H. Wan and D.Jr. Bucaneg. Short-term power fluctuations of large wind power plants. *Journal of Solar Energy Engineering*, 124(4) :427–431, 2002.
- [17] K. Coughlin. Analysis of wind power and load data at multiple time scales. Lawrence Berkeley National Laboratory. [Available online : <http://escholarship.org/uc/item/3b18v105>], 2011.
- [18] C. Ferreira, J. Gama, L. Matias, A. Botterud, and J. Wang. A survey on wind power ramp forecasting. A report from the Argonne U.S. Department of Energy Laboratory. [Available online at <http://www.dis.anl.gov/>], 2010.
- [19] A. Lau and P. McSharry. Approaches for multi-step density forecasts with application to aggregated wind power. *The Annals of Applied Statistics*, 4(3) :1311–1341, 2010.
- [20] P. Pinson. Very-short-term probabilistic forecasting of wind power with generalized logit - normal distributions. *Journal of the Royal Statistical Society : Series C (Applied Statistics)*, 61(4) :555–576, 2012.
- [21] H. Madsen. *Time series analysis*. Chapman & Hall, 2008.
- [22] H. Holttinen. Hourly wind power variations in the Nordic countries. *Wind Energy*, 8(2) :173–195, 2005.
- [23] G. Giebel. *On the benefits of distributed generation of wind energy in Europe*. PhD thesis, Carl von Ossietzky Universität Oldenburg. [Available online : http://www.drgiebel.de/GGiebel_DistributedWindEnergyInEurope.pdf], 2000.
- [24] N. Siebert. *Development of methods for regional wind power forecasting*. PhD thesis, MINES ParisTech. [Available online : <http://pastel.paristech.org>], 2008.
- [25] R. Davy, M. Woods, C. Russell, and P. Coppin. Statistical downscaling of wind variability from meteorological fields. *Boundary-Layer Meteorology*, 135 :161–175, 2010.
- [26] I. Van der Hoven. Power spectrum of horizontal wind speed in the frequency range from 0.0007 to 900 cycles per hour. *Journal of Atmospheric Sciences*, 14(2) :160–164, 1957.
- [27] M.S. Bartlett. Smoothing periodograms from time-series with continuous spectra. *Nature*, 161(4096) :686–687, May 1948.
- [28] P. Welch. The use of fast Fourier transform for the estimation of power spectra : A method based on time averaging over short, modified periodograms. *IEEE Transactions on Audio and Electroacoustics*, 15(2) :70–73, 1967.
- [29] J.W.J. Prakash, R. Ranmchandran, K.N. Nair, K. Sen Gupta, and P.K. Kunhikrishnan. On the spectral behaviour of atmospheric boundary-layer parameters at Thumba, India. *Quarterly Journal of the Royal Meteorological Society*, 119(509) :187–197, 1993.

- [30] J. Gjerstad, S.E. Aasen, H.I. Andersson, I. Brevik, and J. Lovseth. An analysis of low-frequency maritime atmospheric turbulence. *Journal of the Atmospheric Sciences*, 52 :2663–2669, 1995.
- [31] T. Heggem, R. Lende, and J. Lovseth. Analysis of long time series of coastal wind. *Journal of the Atmospheric Sciences*, 55 :2907–2917, 1998.
- [32] B. Tarroja, F. Mueller, J.D. Eichman, J. Brouwer, and S. Samuelson. Spatial and temporal analysis of electric wind generation intermittency and dynamics. *Renewable Energy*, 36(12) :3424 – 3432, 2011.
- [33] A. Viguera-Rodríguez, P. Sørensen, N. A. Cutululis, A. Viedma, and M. H. Donovan. Wind model for low frequency power fluctuations in offshore wind farms. *Wind Energy*, 13(5) :471–482, 2010.
- [34] A.N. Kolmogorov. The local structure of turbulence in incompressible viscous fluid for very large reynolds numbers. *Proceedings of the Royal Society of London. Series A : Mathematical and Physical Sciences*, 434(1890) :9–13, 1991.
- [35] C.L. Vincent, G. Giebel, P. Pinson, and H. Madsen. Resolving nonstationary spectral information in wind speed time series using the Hilbert-Huang transform. *Journal of Applied Meteorology and Climatology*, 49 :253–267, 2010.
- [36] C.L. Vincent, P. Pinson, and G. Giebel. Wind fluctuations over the North Sea. *International Journal of Climatology*, 31(11) :1584–1595, 2011.
- [37] D. Ziou and S. Tabbone. Edge detection techniques - An overview. *International Journal of Pattern Recognition and Image Analysis*, 8 :537–559, 1998.
- [38] N.J. Cutler, M. Kay, K. Jacka, and T.S. Nielsen. Detecting, categorizing and forecasting large ramps in wind farm power output using meteorological observations and WPPT. *Wind Energy*, 10(5) :453–470, 2007.
- [39] B. Greaves, J. Collins, J. Parkes, and A. Tindal. Temporal Forecast Uncertainty for Ramp Events. *Wind Engineering*, 33(11) :309–319, 2009.
- [40] H. Farid and E.P. Simoncelli. Differentiation of discrete multidimensional signals. *Image Processing, IEEE Transactions on*, 13(4) :496 –508, april 2004.
- [41] V. Torre and T.A. Poggio. On edge detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-8(2) :147 –163, 1986.
- [42] A.C. Bovik, T.S. Huang, and D.C. Munson. The effect of median filtering on edge estimation and detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-9(2) :181 –194, march 1987.
- [43] I. Sobel. An isotropic 3×3 gradient operator. In H. Freeman, editor, *Machine Vision for Three - Dimensional Scenes*, Academic Press, pages 376–379, 1990.
- [44] J. Prewitt. Object enhancement and extraction. *Picture Process. Psychopict*, pages 75–149, 1970.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

- [45] M. Basu. Gaussian-based edge-detection methods - A survey. *Systems, Man, and Cybernetics, Part C : Applications and Reviews, IEEE Transactions on*, 32(3) :252 – 260, aug 2002.
- [46] S. Ando. Consistent gradient operators. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22 :252–265, 2000.
- [47] H.G. Senel. Gradient estimation using wide support operators. *Image Processing, IEEE Transactions on*, 18(4) :867 –878, april 2009.
- [48] J. Canny. A computational approach to edge detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-8(6) :679 –698, 1986.
- [49] H.D. Tagare and R.J.P. De Figueiredo. On the Localization performance measure and optimal edge detection. *IEEE Trans. Pattern Anal. Mach. Intell.*, 12(12) :1186–1190, dec. 1990.
- [50] D. Demigny and T. Kamle. A discrete expression of Canny’s criteria for step edge detector performances evaluation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 19(11) :1199 –1211, nov 1997.
- [51] M. Petrou and J. Kittler. Optimal edge detectors for ramp edges. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 13(5) :483 –491, may 1991.
- [52] D. Demigny. On optimal linear filtering for edge detection. *Image Processing, IEEE Transactions on*, 11(7) :728 – 737, 2002.
- [53] O. Laligant, F. Truchetet, and F. Meriaudeau. Regularization preserving localization of close edges. *Signal Processing Letters, IEEE*, 14(3) :185 –188, march 2007.
- [54] S. Mallat. *A wavelet tour of signal processing*. Academic Press, 1998.
- [55] C. Torrence and G.P. Compo. A practical guide to wavelet analysis. *Bulletin of the American Meteorological Society*, 79(1) :61–78, 1998.
- [56] T. Lindeberg. Edge detection and ridge detection with automatic scale selection. *International Journal of Computer Vision*, 30(2) :117–154, 1998.
- [57] T. Lindeberg. Feature detection with automatic scale selection. *International Journal of Computer Vision*, 30(2) :79–116, 1998.
- [58] C. Gallego, A. Costa, Á. Cuerva, L. Landberg, B. Greaves, and J. Collins. A wavelet-based approach for large wind power ramp characterisation. *Wind Energy*, pages n/a–n/a, 2012. DOI : 10.1002/we.550.
- [59] P. Bao, L. Zhang, and X. Wu. Canny edge detection enhancement by scale multiplication. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 27(9) :1485 –1490, sept. 2005.
- [60] T. Lindeberg. Scale-space for discrete signals. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 12(3) :234 –254, mar 1990.
- [61] J. Bigot. *Recalage de signaux et analyse de variance fonctionnelle par ondelettes. Applications au domaine biomédical*. PhD thesis, Université Joseph-Fourier-Grenoble 1. [Available online : <http://tel.archives-ouvertes.fr/docs/00/04/60/08/PDF/tel-00004362.pdf>], 2003.

- [62] J. Babaud, A.P. Witkin, M. Baudin, and R.O. Duda. Uniqueness of the Gaussian kernel for scale-space filtering. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-8(1) :26–33, jan. 1986.
- [63] S. Mallat and S. Zhong. Characterization of signals from multiscale edges. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 14(7) :710–732, jul 1992.
- [64] S. Mallat and W.L. Hwang. Singularity detection and processing with wavelets. *Information Theory, IEEE Transactions on*, 38(2) :617–643, mar 1992.
- [65] J. Bigot. A scale-space approach with wavelets to singularity estimation. *ESAIM : Probability and Statistics*, 9 :143–164, 2005.
- [66] C. Ducottet, T. Fournel, and C. Barat. Scale-adaptive detection and local characterization of edges based on wavelet transform. *Signal Processing*, 84(11) :2115–2137, 2004.
- [67] J.H. Elder and S.W. Zucker. Local scale control for edge detection and blur estimation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 20(7) :699–716, jul 1998.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

Chapitre 3

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection

3.1 Introduction

Dans la littérature éolienne, les travaux traitant de la caractérisation et de la détection des variations brusques et importantes de la production, sont généralement motivés par l'étude des caractéristiques de ces variations : saisonnalités, prédictibilité, etc. Les aspects liés à la qualité des approches de détection sur lesquelles ils reposent n'en constituent jamais ou presque l'objet. Ces travaux reposent ainsi parfois sur des approches de détection ad hoc. La notion même de performances permettant de garantir l'adéquation de ces approches y est généralement absente [1, 2, 3].

La proposition d'une approche de détection ne peut être entérinée que si cette dernière est évaluée selon un certain protocole. Dans la littérature de détection de ruptures, le développement et l'évaluation d'une approche de détection font généralement intervenir un modèle de rupture et des critères d'évaluation (e.g. les critères de Canny [4]). Il n'existe pas de paradigme comme celui-ci dans les travaux issus de la littérature éolienne. Dans [1] par exemple, il est fait état d'une approche reposant sur une forme singulière de filtrage (définie par l'Equation (2.1)). Ce filtre a été introduit sans qu'aît été précisée à priori la nature des variations à détecter, ou celle du bruit dans lequel cette détection avait lieu. Nous ignorons ainsi quelle géométrie de rupture, si il en est, ce filtre permet de détecter, et quel peut être son comportement vis-à-vis d'autres éléments d'un signal de production (e.g. bruit, ruptures voisines, ...).

Au-delà du choix d'un filtre particulier, une question essentielle dans la détection des rup-

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

tures d'un signal est celle de la sélection d'une (ou plusieurs) échelle(s) appropriée(s). Nous avons vu dans le chapitre précédent qu'à travers cette sélection, il s'agit généralement d'optimiser (localement ou non) un compromis entre l'atténuation du bruit et la limitation des interactions dues à la présence de ruptures voisines. Nous avons vu également qu'à travers une approche multi-échelle, il peut s'agir de chercher à définir une caractérisation absolue d'une rupture, et non relative à une échelle particulière. Cette caractérisation peut se traduire par exemple par l'estimation de paramètres définissant la géométrie d'un modèle de rupture (comme dans [5, 6]). Dans la littérature éolienne, cette problématique a notamment été abordée dans [3]. L'intensité d'une variation y est définie à partir de la somme des réponses d'un filtre à différentes échelles. Cependant, l'analyse qui est faite de leur approche provient de l'étude de cas particuliers. De plus, la proposition d'une telle approche soulève un certain intérêt vis-à-vis d'approches alternatives.

Dans ce chapitre, on se propose dans un premier temps de définir un cadre d'évaluation des différents filtres et approches de détection de ruptures rencontrés dans la littérature éolienne et de traitement du signal. Ce cadre s'inspire des travaux présents dans la littérature de traitement du signal, puisqu'il se compose à la fois d'un modèle de rupture, et de critères de performances. Afin de reproduire correctement certains aspects du processus de production éolienne (e.g. borné et non-stationnaire), le modèle de rupture que nous proposons se différencie des modèles proposés dans la littérature (voir entre autres [4, 7, 8]). Il tient notamment compte du caractère aléatoire avec lequel deux ruptures consécutives d'un signal de production se succèdent.

Dans un deuxième temps, nous utilisons les résultats de simulations issues de ce modèle pour réaliser une étude paramétrique de différents filtres et approches de détection. En particulier, nous évaluons les performances du filtre proposé dans [1], et de l'approche multi-échelle proposée dans [3].

Le chapitre s'organise comme suit : dans la Section 3.2 nous décrivons le modèle de rupture que nous proposons. Nous commençons par définir un profil de ruptures, dans lequel sont modélisés la proximité de deux ruptures consécutives et leur caractère aléatoire. Nous ajoutons à ce profil du bruit destiné à reproduire les fluctuations les plus rapides de la production. Nous veillons, à travers la modélisation de ce dernier, à respecter le caractère borné du processus de production, ainsi que certains des aspects de sa non-stationnarité. Nous définissons également dans cette section les critères de performances associés au modèle qui constituent notre cadre d'évaluation. Dans la Section 3.3, nous étudions les performances de détection et de localisation d'une rupture de 3 filtres différents. Dans la Section 3.4, nous étudions les performances de détection de différentes approches multi-échelles. Enfin, une synthèse des travaux présentés dans ce chapitre est donnée dans la dernière section.

3.2 Proposition d'un cadre d'évaluation des approches de détection des variations brusques et importantes de la production éolienne

Dans cette section, nous définissons un cadre adapté pour l'évaluation de filtres et d'approches de détection des variations brusques et importantes de la production éolienne. Ce cadre est composé d'un modèle de rupture, représentant certaines des caractéristiques principales des variations de la production éolienne. Il lui est associé des critères de performances permettant d'évaluer une approche de détection à partir de simulations.

3.2.1 Définition d'un modèle de rupture

Comme il est courant de le faire dans la littérature de traitement du signal [4, 7, 8, 9], nous considérons un modèle de rupture faisant intervenir une décomposition dans laquelle un signal p_t à un instant t , s'écrit sous la forme suivante :

$$p_t = R_t + \epsilon_t, \quad (3.1)$$

où R désigne un *profil de ruptures*, et où ϵ désigne un bruit. A travers un tel modèle, on cherche ici à étudier différentes approches de détection. On s'intéresse notamment à la robustesse de ces approches au bruit ϵ , dans l'estimation de certains paramètres définissant R (e.g. instant d'apparition d'une rupture). Idéalement, la forme de R introduit une géométrie de rupture particulière que l'on cherche à détecter. En l'absence de géométrie connue *ex ante*, il convient de limiter la constitution de R à certains éléments représentatifs de paramètres de détection a priori influents (e.g. la proximité de ruptures voisines). Nous discutons maintenant de la définition d'un profil de ruptures R , avant de traiter de celle du bruit ϵ .

Définition d'un profil de ruptures

Comme nous l'avons vu dans le chapitre précédent (Section 2.3.1, notamment à travers l'exemple illustré Figure 2.5), la proximité des ruptures d'un signal constitue un paramètre de détection important. Dans un modèle de rupture, ce paramètre prend souvent la forme d'une distance *fixe* séparant deux ruptures consécutives de sens contraires [7, 8]. Il n'est cependant pas possible ainsi de représenter le caractère aléatoire avec lequel deux variations brusques d'un processus non-stationnaire se succèdent.

Dans le modèle que nous proposons, nous considérons la durée séparant deux ruptures consécutives, ainsi que la durée de chacune de ces ruptures, comme des variables aléatoires. Le profil R y représente la succession d'épisodes de production constante, ainsi que les transitions entre ces épisodes. Les transitions entre épisodes sont modélisées par des segments représentant les ruptures. Le caractère brusque d'une rupture peut alors être complètement

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

représenté par l'association d'une durée T_i et d'une amplitude A . L'amplitude des ruptures dans un signal de production éolienne possède elle aussi un caractère aléatoire. Etudier sa nature nécessite de disposer d'une approche permettant d'estimer l'amplitude des ruptures dans un signal numérique (voir [5], [6] ou [10]). Une étude préliminaire basée sur l'analyse de simulations et de signaux de production réels à partir d'une approche de maxima d'ondelettes, a montré la difficulté d'obtenir des estimations satisfaisantes. Afin de limiter la dimension de notre étude, nous avons choisi d'étudier les performances d'approches de détection à partir de signaux dans lesquels les ruptures sont d'amplitudes égales. La considération de différentes valeurs d'amplitude d'une rupture à partir de différentes simulations, doit permettre dans une certaine mesure d'étudier l'influence de ce paramètre sur les performances de détection.

En considérant l'alternance d'épisodes de production nulle, avec des épisodes de production égale à A , le profil R de notre modèle est défini par la succession de N profils élémentaires R^k , chacun d'une durée aléatoire. Formellement, on a :

$$\begin{aligned} R &= (R^1, \dots, R^k, \dots, R^N), \\ R^k &= (R_1^k, \dots, R_t^k, \dots, R_{T^k}^k), \quad 1 \leq k \leq N, \\ T^k &= T_1^k + T_2^k + T_3^k + T_4^k, \end{aligned} \quad (3.2)$$

$$R_t^k = \begin{cases} 0 & \text{si } t \in [0, T_1^k], \\ \frac{A}{T_2^k}(t - T_1^k) & \text{si } t \in [T_1^k, T_1^k + T_2^k], \\ A & \text{si } t \in [T_1^k + T_2^k, T_1^k + T_2^k + T_3^k], \\ -\frac{A}{T_4^k}(t - T^k) & \text{si } t \in [T_1^k + T_2^k + T_3^k, T^k], \end{cases} \quad (3.3)$$

où T_1^k (resp. T_3^k) représente la durée d'un épisode de production nulle (resp. égale à A), et T_2^k (resp. T_4^k) la durée d'une rupture croissante (resp. décroissante). Un schéma représentant le profil élémentaire R^k définissant la géométrie de notre modèle de rupture est donné un peu plus loin en Figure 3.3. A partir du modèle défini ci-dessus, la simulation d'un profil de ruptures R provient de N tirages aléatoires T_i^k , $k = 1, \dots, N$, $i = 1, \dots, 4$. Cette simulation permet d'introduire dans la détection d'une rupture, les interactions dues à la présence non pas d'une (comme dans [7, 8]), mais de plusieurs autres ruptures plus ou moins distantes les unes des autres.

Les variables aléatoires T_i (l'indice k a été supprimé afin d'alléger les notations) sont des variables continues représentant des durées. Nous les supposons indépendantes, et les modélisons par des lois exponentielles tronquées $T_i \sim \text{Exp}_{\theta_m^i}^{\theta_M^i}(\lambda_i)$, $(\theta_m^i, \theta_M^i, \lambda_i) \in (\mathbb{R}_+^*)^3$. La fonction de densité de probabilité $f_{\theta_m, \theta_M}^\lambda$ de la loi exponentielle de paramètre λ , restreinte à l'intervalle $[\theta_m, \theta_M]$, est donnée par :

$$f_{\theta_m, \theta_M}^\lambda(x) = \frac{e^{-x/\lambda}}{\lambda(e^{-\theta_m/\lambda} - e^{-\theta_M/\lambda})} \mathbb{1}_{[\theta_m, \theta_M]}(x).$$

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection

L'espérance λ_T d'une variable aléatoire $T \sim \text{Exp}_{\theta_m}^{\theta_M}(\lambda)$ peut s'écrire sous la forme suivante :

$$\lambda_T = \lambda + \frac{\theta_m e^{-\theta_m/\lambda} - \theta_M e^{-\theta_M/\lambda}}{e^{-\theta_m/\lambda} - e^{-\theta_M/\lambda}}.$$

Afin d'aboutir à des hypothèses réalistes, nous avons réalisé une analyse reposant sur des mesures, échantillonnées toutes les 10 mn, et couvrant plus de un an et demi de production de trois fermes Françaises. Dans la Figure 3.1 (graphique de gauche) sont représentées des estimations de la distribution de la dérivée d'un signal de production réalisées à partir du filtre de Prewitt (Equation (2.3)), et de mesures de production d'une ferme éolienne. On peut voir dans cette figure que la distribution de la dérivée d'un signal de production d'une ferme présente un aspect plus ou moins symétrique (voir aussi [11]). Alors qu'on observe davantage de variations décroissantes parmi les variations de plus faible intensité, la fréquence des variations de plus forte intensité est sensiblement la même entre les variations croissantes et décroissantes (Figure 3.1, graphique de droite). Pour des ruptures dont on suppose qu'elles sont d'amplitudes égales, ceci se traduit par un caractère brusque identique entre ruptures croissantes et décroissantes. Dans notre modèle, nous supposons ainsi que T_2 et T_4 suivent la même loi, i.e. $\theta_m^2 = \theta_m^4$, $\theta_M^2 = \theta_M^4$ et $\lambda_2 = \lambda_4$. L'observation plus fréquente de faibles valeurs

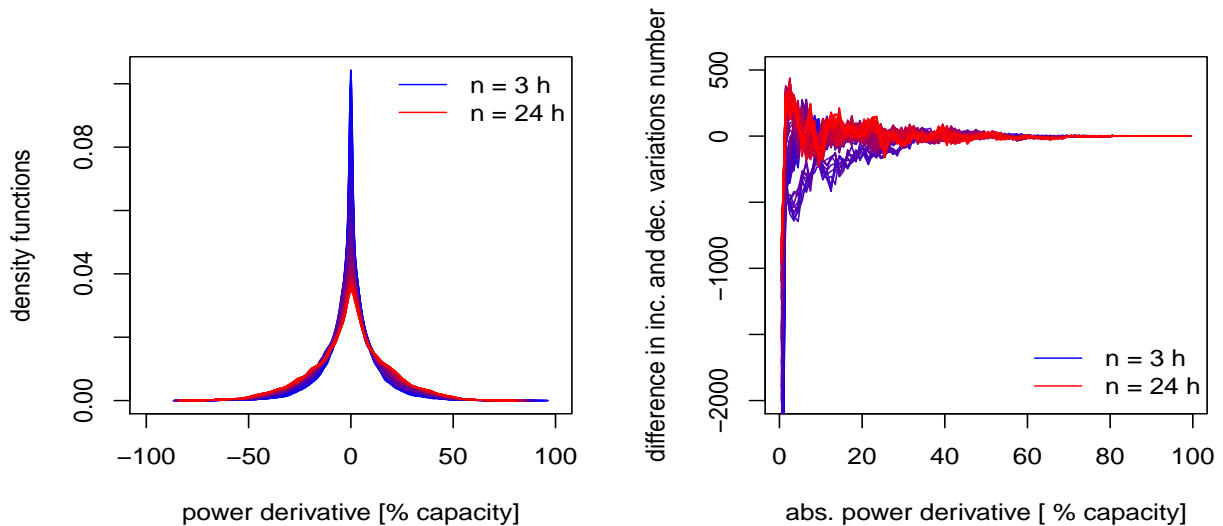


FIGURE 3.1 – Distribution de la dérivée d'un signal de production – A gauche : estimation par noyau de la fonction de densité de probabilité de la distribution d'un signal de production dérivé. La dérivée du signal de production a été estimée ici à l'aide du filtre de Prewitt (2.3), pour des largeurs de filtre allant de 3 h à 24 h, par pas de 20 mn. A droite : différence entre le nombre de variations croissantes et décroissantes, en fonction de la mesure de ces variations. Parmi les variations de plus faible intensité, on observe un déséquilibre en faveur d'un plus grand nombre de variations décroissantes. En revanche, la fréquence des variations de plus forte intensité est sensiblement la même pour les variations croissantes et décroissantes.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

de production laisse penser que les épisodes de faible production sont généralement plus longs que ceux de forte production. Nous supposons donc que $\lambda_{T_1} > \lambda_{T_3}$.

Définition du bruit

Une hypothèse souvent rencontrée dans la littérature de traitement du signal (voir notamment [4, 6, 7, 8, 9]), consiste à modéliser ϵ par un bruit blanc Gaussien. A un instant donné t , ϵ_t désigne alors une variable aléatoire suivant une loi Gaussienne de moyenne nulle, et de variance σ^2 . Les variables aléatoires associées à différents instants sont supposées indépendantes et identiquement distribuées :

$$\begin{aligned}\epsilon_t &\sim \mathcal{N}(0, \sigma^2), \forall t \in \mathbb{R}_+, \\ \mathbb{E}[\epsilon_i \epsilon_j] &= 0, i \neq j.\end{aligned}$$

Ces hypothèses ne conviennent pas à la nature bornée et non-stationnaire du processus de production. A mesure que l'on s'approche des valeurs de production nulle et maximale, la distribution de la production présente un étalement réduit, une plus grande asymétrie, et potentiellement des concentrations massiques ponctuelles en 0 et au niveau de sa valeur nominale¹.

Pour représenter adéquatement ces caractéristiques à partir du modèle (3.1), il est nécessaire de modéliser le bruit à l'aide d'une distribution bornée, dont l'étalement et l'asymétrie varient avec le niveau de production. Nous proposons de modéliser le bruit ϵ_t par une distribution Gaussienne tronquée $\mathcal{N}_{-p}^{100-p}(0, \sigma_p^2)$, restreinte à l'intervalle $[-p, 100-p]$, où $p \in [0, 100]$ désigne le niveau de production représenté par le profil de ruptures (exprimé en pourcentage de la valeur de production nominale). Certaines alternatives pourraient constituer des choix plus appropriés. Dans un contexte de prédiction à court terme de la production, la distribution de la production est parfois représentée par une loi beta [12], ou par une loi logit-normale intégrant [13] ou non [14] la présence de masses ponctuelles. Dans l'étude du comportement d'approches de détection de ruptures utilisées sur des signaux de production éolienne, une représentation plus adéquate de la distribution de la production pourrait offrir de nouvelles informations. Si des efforts supplémentaires dédiés à cette représentation offrent une perspective de travail intéressante, ils demeurent néanmoins en dehors du cadre de cette étude.

La fonction de densité de probabilité d'une loi $\mathcal{N}_{-p}^{100-p}(0, \sigma_p^2)$ est donnée par :

$$g_{p, \sigma_p}(x) = \frac{g_{\sigma_p}(x)}{\Phi_{\sigma_p}(100-p) - \Phi_{\sigma_p}(-p)} \mathbb{1}_{[-p, 100-p]}(x),$$

où g_{σ_p} désigne la fonction de densité de probabilité d'une loi Gaussienne centrée d'écart-type σ_p , et Φ_{σ_p} sa fonction de répartition. L'espérance $\mu_{tr, p}$ et la variance $\sigma_{tr, p}^2$ de la loi $\mathcal{N}_{-p}^{100-p}(0, \sigma_p^2)$

1. L'existence de masses ponctuelles dépend toutefois du niveau d'agrégation auquel la production est observée

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection

sont données par :

$$\mu_{tr,p} = \sigma_p^2 \frac{g_{\sigma_p}(-p) - g_{\sigma_p}(100-p)}{\Phi_{\sigma_p}(100-p) - \Phi_{\sigma_p}(-p)},$$

$$\sigma_{tr,p}^2 = \sigma_p^2 \left[1 + \frac{-pg_{\sigma_p}(-p) - (100-p)g_{\sigma_p}(100-p)}{\Phi_{\sigma_p}(100-p) - \Phi_{\sigma_p}(-p)} - \frac{\mu_{tr,p}^2}{\sigma_p^2} \right].$$

Dans la Figure 3.2 sont montrées des estimations de l'écart-type de la production d'une ferme en fonction du niveau de production. Ces dernières montrent un écart-type croissant avec le niveau de production. Cette accroissement a tendance à diminuer, voir même à s'annuler (pour ici devenir négatif), dès lors que le niveau de production est suffisamment élevé. Afin d'introduire cet aspect dans notre modèle, nous représentons l'évolution de l'écart-type $\sigma_{tr,p}$ du bruit, en fonction du niveau de production p , par une fonction linéaire par morceaux :

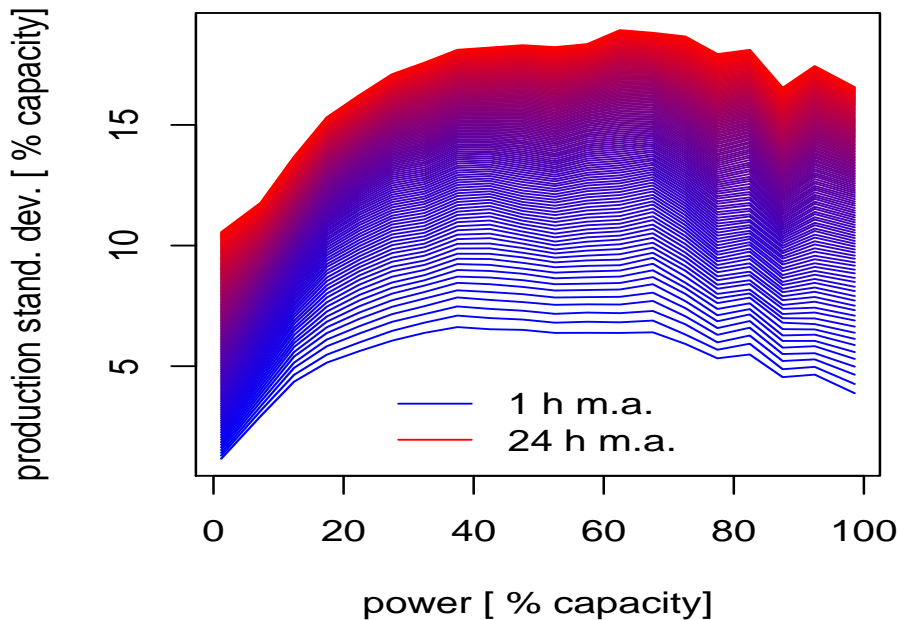


FIGURE 3.2 – Ecart-type de la production en fonction du niveau de production – *L'estimation de l'écart-type provient ici d'estimations empiriques calculées par fenêtres glissantes, pour des largeurs de fenêtre allant de 1 h à 24 h , par pas de 20 mn. On observe bien ici comment à mesure que l'on s'éloigne des valeurs de production nulle, la distribution de la production devient plus étalée. Cet étalement a tendance ici à se stabiliser, voire à réduire, lorsque l'on s'approche de la valeur de production nominale. Les résultats présentés ici sont issus de l'analyse de 18 mois de mesures de production provenant d'une ferme Française de 8 MW, et échantillonnées toutes les 10 mn.*

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

$$\sigma_{tr,p}(p) = (\alpha_1 p + \beta_1) \mathbb{1}_{[0,p_1]}(p) + \beta_2 \mathbb{1}_{[p_1,100]}(p), \quad (3.4)$$

où $0 < p_1 < 100$, et $\alpha_1, \beta_1, \beta_2 \in \mathbb{R}_+^*$. Afin de conserver un aspect régulier dans son évolution en fonction de p , il convient d'imposer la continuité de $\sigma_{tr,p}$ au niveau du noeud p_1 , ce qui nous permet de réécrire (3.4) de la manière suivante :

$$\sigma_{tr,p}(p) = a_1 + a_2 p - a_2 (p - p_1)_+, \quad (3.5)$$

où $a_i > 0, \forall i$, et $(\cdot)_+$ désigne la partie positive. Enfin, nous supposons que l'auto-corrélation du processus de production est entièrement représentée à travers la définition du profil R . Autrement dit, nous supposons que le bruit $(\epsilon_t)_t$ est non corrélé.




FIGURE 3.3 – Profil de ruptures et distribution du bruit – Schéma représentant un profil élémentaire de ruptures R^k défini par l'Equation (3.3). Sont représentées : l'amplitude A d'une rupture, les durées $T_i, i = 1, \dots, 4$ des ruptures et des épisodes de production constante, ainsi que la distribution du bruit associée au niveau de production p .

3.2.2 Conditions expérimentales et simulations

Nous décrivons ici les valeurs des paramètres du modèle décrit dans la sous-section précédente, que nous utilisons afin de simuler la production et ses ruptures.

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection

L'altération de la géométrie d'une rupture par le bruit dépend des niveaux de production en début et en fin de celle-ci. Le comportement d'une approche de détection peut ainsi varier avec les niveaux de production en question. Toutefois, nous nous restreindrons à étudier la détection de ruptures pour lesquelles le niveau de production minimum est nul. Le profil de ruptures R d'amplitude A que nous considérons est ainsi exactement représenté par les Equations (3.2) et (3.3). Ce profil est adapté à la représentation de signaux de production dont le niveau d'agrégation n'est pas trop important, et pour lequel l'apparition d'épisodes de production nulle ou presque est récurrente. Nous considérons des ruptures d'amplitude $A = 50, 60, 70, 80, 90$ et 100% de la valeur de production nominale.

La durée des épisodes de faible (resp. forte) production, ainsi que celle des ruptures, constituent des paramètres essentiels dans l'analyse des performances d'une approche de détection. Nous analyserons ces performances en faisant varier ces paramètres, cherchant ainsi à simuler différentes conditions de production. Les durées moyennes des épisodes de production nulle, et des épisodes de production de valeur A , sont supposées ici liées par un facteur multiplicatif c , i.e. $\lambda_{T_1} = c \lambda_{T_3}$, $c \geq 1$. Nous considérons des valeurs de $c = 1, 1.5, 2, 3, 5$, et de $\lambda_{T_1} = 6, 12, 24, 48, 96$ h. Il n'est pas question de chercher ici des valeurs représentatives de ce que peut être la fréquence d'apparition d'une rupture dans un signal de production éolienne. Leur estimation devrait faire l'objet d'une étude basée sur l'utilisation d'outils dont nous nous offrons d'évaluer l'adéquation. Il est davantage question ici de considérer des valeurs qui, en conjonction avec celles d'échelles de détection choisies (décrites dans les sections suivantes), permettent de révéler certaines caractéristiques des approches de détection étudiées.

La durée maximale d'un épisode de production nulle est quant à elle fixée à $\theta_M^1 = 20$ j. Ce choix est en adéquation avec certains résultats issus d'autres travaux. Dans [15], la durée d'attente d'un épisode de vent faible long de 20 j est par exemple estimée à 1 tous les 10 ans (en zones côtières). Dans ces conditions, il semble hautement improbable pour un épisode de production nulle d'excéder une durée de 20 j. Nous supposons que la durée maximale θ_M^3 d'un épisode de production de valeur A , est liée à θ_M^1 de la même manière que le sont les durées moyennes respectives, i.e. $\theta_M^1 = c \theta_M^3$. Nous supposons de plus qu'une rupture croissante ne peut être suivie d'une rupture décroissante dans une durée inférieure à $\theta_m^3 = 1$ h. Nous écartons également les situations identifiables à des cas extrêmes de *cut-off*² en fixant $\theta_m^1 = 1$ h. Encore une fois, nous nous appuyons ici sur des valeurs établies sur la base de notre jugement. Ces valeurs nécessiteraient d'être vérifiées à fortiori.

Enfin, pour ce qui est de la durée d'une rupture, nous faisons varier sa valeur moyenne $\lambda_{T_2} = 1/6, 1/2, 1, 2, 3$ h, tout en supposant que sa durée maximale n'excède pas $\theta_M^2 = 6$ h. Sa durée minimale θ_m^2 est quant à elle fixée à 10 mn, ce qui correspond aussi à la résolution temporelle choisie pour simuler la production.

Nous avons considéré également deux catégories de bruit. La première correspond à un bruit de faible intensité, et est caractérisée par des valeurs de paramètres $a_1 = 2.5\%P_n$ (P_n

2. Un "cut-off" fait référence aux situations de vents très forts entraînant un arrêt momentané des turbines par mesure de sécurité, et donc une baisse soudaine de la production. Un léger affaiblissement du vent suffit ensuite pour que les turbines redémarrent, et que la production retrouve rapidement un niveau élevé.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne




FIGURE 3.4 – Exemples de simulations – Deux épisodes de production de 7 j simulés suivant le modèle de rupture proposé. Dans les deux cas présentés ici l'amplitude des ruptures a été fixée à $A = 80\%$ de la valeur de production nominale. En haut est représenté un épisode avec un bruit de faible intensité, en bas un épisode avec un bruit de forte intensité (voir le texte pour plus de détails). Dans l'épisode représenté en haut, les ruptures sont en moyenne moins abruptes que celles dans l'épisode représenté en bas ($\lambda_{T_2} = 3$ h, contre 1/2 h en bas). La durée d'un épisode de production nulle y est en moyenne plus longue ($\lambda_{T_1} = 48$ h, contre 12 h en bas), mais avec un ratio caractérisant la durée moyenne des épisodes de production élevée plus important ($c = 5$, contre $c = 2$ en bas).

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection

désigne ici la valeur de production nominale), $a_2 = 10\%P_n$ et $p_1 = 25\%P_n$ dans l'Equation (3.5). La seconde à un bruit de forte intensité caractérisée par des valeurs de paramètres $a_1 = 5\%P_n$, $a_2 = 20\%P_n$ et $p_1 = 25\%P_n$. Des exemples d'épisodes de production de 7 j simulés à partir de notre modèle de rupture sont présentés Figure 3.4. Dans la suite, nous considérerons des épisodes de production provenant de la simulation de $N = 100$ profils élémentaires de ruptures R^k (voir Equations (3.2) et (3.3)).

TABLE 3.1 – Tableau récapitulatif des paramètres du modèle de rupture – Les valeurs présentées ici ont servi à la simulation de signaux de production et de leurs ruptures utilisés dans l'analyse qui suit. A titre d'exemple, les valeurs représentées en gras dans le tableau ont servi dans les simulations ayant produit les signaux représentés dans la Figure 3.4

Caractéristiques	Paramètres	Unités	Valeurs
Profil de ruptures R			
Amplitude d'une rupture	A	$\%P_n$	50, 60, 70, 80 , 90, 100
Durée moyenne d'une rupture	λ_{T_2} ($= \lambda_{T_4}$)	h	1/6, 1/2 , 1, 2, 3
Durée minimale d'une rupture	θ_m^2 ($= \theta_m^4$)	h	1/6
Durée maximale d'une rupture	θ_M^2 ($= \theta_M^4$)	h	6
Durée moyenne d'un épisode de production nulle	λ_{T_1}	h	6, 12 , 24, 48 , 96
Durée minimale d'un épisode de production nulle	θ_m^1	h	1
Durée maximale d'un épisode de production nulle	θ_M^1	j	20
Durée moyenne d'un épisode de production égale à A	λ_{T_3}	h	$c \lambda_{T_1}$
Durée minimale d'un épisode de production égale à A	θ_m^3	h	1
Durée maximale d'un épisode de production égale à A	θ_M^3	j	$c \theta_M^1$
Ratio $\lambda_{T_1}/\lambda_{T_3}$	c	-	1, 1.5, 2 , 3, 5
Evolution du bruit avec le niveau de production p			
Ecart-type du bruit $\sigma_{tr,p}$ en fonction de p	a_1, a_2, p_1	$\%P_n$	$j \times 2.5, j \times 10, 25$
Niveau d'intensité du bruit	j	-	1, 2

3.2.3 Critères d'évaluation

Dans la littérature de détection de ruptures, l'évaluation des performances d'un filtre ou plus généralement d'une approche de détection, fait souvent intervenir les critères de Canny (voir Section 2.3.1). Nous utilisons notamment ces critères pour étudier les performances de différents filtres de détection dans la section suivante. On peut toutefois envisager d'utiliser d'autres critères d'évaluation, en lieu et place du premier critère de Canny notamment. Nous détaillons ici en quoi l'évaluation d'une approche de détection à partir d'un modèle de rupture, peut être vue comme celle d'un problème de classification supervisée. Nous décrivons

également certains critères, issus de la littérature de classification, que nous utiliserons dans l'évaluation d'approches de détection multi-échelles en Section 3.4.

L'évaluation d'une approche de détection de ruptures vue comme celle d'un problème de classification

De manière générale, une approche de détection repose sur une mesure des variations d'un signal. Cette dernière quantifie le caractère brusque et important d'une variation au cours du temps. Il est possible de réduire la description d'une variation à un certain nombre de paramètres caractéristiques : un repère temporel particulier (e.g. nous avons défini dans la section 2.3.1 l'instant d'apparition t_I d'une variation), une mesure à un instant donné des caractères brusque et important associés (e.g. l'intensité I d'une variation), un ensemble de mesures d'intensité à différentes échelles, ou encore une amplitude et un paramètre de lissage directement estimables à partir de cet ensemble. Nous considérons une caractérisation des variations réduite à seulement deux paramètres : l'instant d'apparition t_I , et l'intensité I d'une variation. A travers la considération de différentes approches de détection, on est amené à considérer différentes définitions de ces deux paramètres.

La définition de l'intensité d'une variation établit (avec les caractéristiques d'un signal), la distribution statistique des mesures d'intensité des variations d'un signal. Une définition adaptée à la caractérisation des ruptures, lorsque employée sur des signaux de production simulés à partir de notre modèle, donne à la distribution de $I \in \mathcal{I}$ la forme d'un mélange à deux composantes. Une première composante associée aux faibles valeurs de $|I|$ et caractérisant les variations dues au bruit. Une seconde composante associée aux fortes valeurs de $|I|$ et caractérisant les ruptures. A une mesure d'intensité des variations, une approche de détection associe une procédure de seuillage. A travers la sélection d'une valeur d'intensité seuil $\tau \in]0, \sup \mathcal{I}]$, cette dernière définit une règle de classification des variations $f_\tau : \mathcal{I} \rightarrow \{0, 1\}$:

$$f_\tau(I) = \mathbb{1}_{\{|I| \geq \tau\}}.$$

L'utilisation d'une approche de détection sur des signaux dans lesquels est connue la position des ruptures, permet d'associer à chaque variation d'intensité I et au résultat de sa classification $f_\tau(I)$, une variable $Y \in \{0, 1\}$ désignant s'il s'agit réellement ou non d'une rupture ($Y = 1$ s'il s'agit d'une rupture, $Y = 0$ sinon). L'évaluation d'une approche de détection revient ainsi à évaluer les résultats d'un exercice de classification.

L'identification d'une rupture repose notamment sur la capacité d'une approche à estimer correctement son instant d'apparition. Il est ainsi nécessaire d'introduire un paramètre δ , représentant l'erreur maximale d'estimation de l'instant d'apparition d'une rupture, pour laquelle cette dernière est considérée comme détectée. Notre modèle de rupture impose à deux ruptures consécutives de même sens une séparation d'une durée au moins égale à 2 h et 20 mn. Afin d'éviter toute confusion entre deux ruptures distinctes, nous fixons la valeur de δ à 1 h et 10 mn.

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection

La mesure de l'intensité d'une rupture, lorsqu'elle repose sur l'existence d'un maximum local dans un signal dérivé (en valeur absolue), n'est pas toujours définie. Dans le cas d'un filtrage effectué à une échelle (suffisamment grande) par exemple : la présence de deux ruptures proches de sens contraires dans le support d'un filtre donne parfois lieu à un signal dérivé de faible valeur absolue sans présence d'aucun maximum. La largeur de filtre, trop importante relativement à la durée qui sépare ces ruptures, ne permet pas de mesurer ces dernières correctement, et donc d'en définir une intensité caractéristique. Il est dans ce cas malgré tout possible de définir le résultat de classification associé, les ruptures en questions étant considérées comme non détectées, i.e. $f_\tau(I) = 0, \forall \tau \in]0, \sup \mathcal{I}]$. On peut ainsi, par convention, leur associer la mesure d'intensité $I = 0$. L'algorithme utilisé afin de collecter l'échantillon $(I_l, Y_l)_l$ issu de l'utilisation d'une approche de détection sur un signal de production simulé à partir de notre modèle, est donné Table 3.2.

TABLE 3.2 – Algorithme de construction de l'échantillon $(I_l, Y_l)_l$ –

N : nombre de profils élémentaires de ruptures simulés
 t_l^r : instant d'apparition d'une rupture $l, l = 1, \dots, 2N$
 i_k : mesure d'intensité d'une variation $k, k \in \mathcal{K}$
 t_k : instant d'apparition d'une variation $k, k \in \mathcal{K}$
 δ : erreur maximale admise dans l'estimation de l'instant d'apparition d'une rupture

```

for  $l = 1 : 2N$ 
   $Y_l = 1$ 
   $\mathcal{K}' = \{k \in \mathcal{K} \mid t_k \in [t_l^r - \delta, t_l^r + \delta], \text{sign}(i_k) == \text{direction de la rupture } l\}$ 
  if  $\mathcal{K}' \neq \emptyset$ 
     $I_l = i_{k^*}, k^* = \underset{k \in \mathcal{K}'}{\text{argmax}} |i_k|$ 
     $\mathcal{K} = \mathcal{K} \setminus \{k^*\}$ 
  else
     $I_l = 0$ 
  end if
end for
 $l' = 0$ 
for  $k$  left in  $\mathcal{K}$ 
   $l' = l' + 1$ 
   $I_{2N+l'} = i_k$ 
   $Y_{2N+l'} = 0$ 
end for

```

Classification et évaluation : courbe ROC et aire sous la courbe ROC

Nous décrivons ici certains critères couramment utilisés dans la littérature de classification pour évaluer et comparer différents classifieurs. Nous limitons ici la discussion au cas de la classification supervisée à deux classes. Pour une introduction exhaustive à la classification, nous renvoyons le lecteur à [16]. Soit $X \in \mathcal{X}$ un vecteur descriptif d'un élément appartenant à une classe $Y \in \{0, 1\}$. De manière générale, un classifieur $f_\tau, \tau \in \mathbb{R}$ fait intervenir une transformation $\mu : \mathcal{X} \rightarrow \mathbb{R}$, à partir de laquelle il classe cet élément de la manière suivante :

$$f_\tau(X) = \mathbb{1}_{\mu(X) \geq \tau}.$$

On définit l'erreur moyenne de classification \mathcal{E}_τ , associée au classifieur f_τ , par :

$$\mathcal{E}_\tau = \mathbb{E}[|Y - f_\tau(X)|] = \mathbb{P}(f_\tau(X) \neq Y).$$

La formule de Bayes permet de décomposer cette dernière en une moyenne pondérée des deux types d'erreur de classification rencontrés : $\{f_\tau(X) = 1 \cap Y = 0\}$ et $\{f_\tau(X) = 0 \cap Y = 1\}$:

$$\mathcal{E}_\tau = \pi_0 q_\tau + \pi_1 (1 - p_\tau), \quad (3.6)$$

où $\pi_i = \mathbb{P}(Y = i)$, $\pi_0 + \pi_1 = 1$ désignent les probabilités associées à chaque classe, $q_\tau = \mathbb{P}[f_\tau(X) = 1 | Y = 0]$ et $1 - p_\tau = \mathbb{P}[f_\tau(X) = 0 | Y = 1]$. La valeur de seuil τ contrôle ce qui est généralement un compromis entre ces deux erreurs, puisque q_τ décroît alors même que $1 - p_\tau$ croît généralement avec τ . Ce compromis peut être représenté graphiquement à l'aide d'une courbe dite ROC (*Receiver Operating Characteristics curve*) [17]. Il s'agit d'une courbe paramétrée par τ , représentant la probabilité p_τ en fonction de la probabilité q_τ :

$$\text{ROC} = \{(q_\tau, p_\tau), \tau \in \mathbb{R}\}.$$

Comparer deux approches de classification f_τ^1 et f_τ^2 , reposant respectivement sur deux transformations différentes μ_1 et μ_2 , ne peut être fait objectivement à partir d'une valeur de seuil donnée. Cette valeur définit pour deux approches différentes, des caractéristiques différentes au sein du compromis existant entre les deux types d'erreur de classification. On peut en revanche comparer les erreurs respectives, obtenues pour chaque approche, à partir d'une valeur de seuil $\tau_{\text{opt}} = \arg\min_\tau \mathcal{E}_\tau$ définissant une règle de classification optimale. On peut à cet effet introduire un coût relatif C , $0 < C < 1$, contrôlant la pondération des différents types d'erreur de classification (en remplaçant π_0 et π_1 , par respectivement $C\pi_0$ et $(1 - C)\pi_1$ dans l'Equation (3.6)). Une alternative peut être de considérer l'*aire* sous la courbe ROC, notée AUC (*Area Under the ROC Curve*), comme métrique de performances :

$$\text{AUC} = \int_{-\infty}^{+\infty} p_\tau q'_\tau d\tau.$$

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d’approches de détection

Cette dernière a le mérite d’être objective puisque, sans fixer de valeur de seuil, elle ne présume pas de caractéristiques préférentielles au sein du compromis entre les différents types d’erreur de classification. On peut montrer que son calcul revient à intégrer l’erreur moyenne de classification \mathcal{E}_τ sur un ensemble de valeurs de seuil, optimales vis-à-vis de différentes valeurs de coût C [18]. Une méthode classique d’estimation, à partir d’un échantillon $(X_k, Y_k)_k$, est fournie par la U statistique de *Mann-Whitney-Wilcoxon* [19] :

$$U = \text{AUC} = \frac{1}{\#\mathcal{K}_0 \#\mathcal{K}_1} \sum_{k \in \mathcal{K}_0} \sum_{l \in \mathcal{K}_1} \mathbb{1}_{\{\mu(X_l) > \mu(X_k)\}},$$

où $\mathcal{K}_0 = \{k | Y_k = 0\}$ et $\mathcal{K}_1 = \{k | Y_k = 1\}$. L’aire sous la courbe ROC est comprise entre 1/2 et 1. Une valeur de 1 signifie que les composantes de la distribution de $\mu(X)$ associées aux classes $Y = 0$ et $Y = 1$ sont de supports disjoints. Toute valeur de seuil τ comprise dans l’intervalle réel les séparant offre une classification parfaite, i.e. une erreur moyenne de classification nulle. A l’inverse, le cas de deux composantes identiques (et donc d’une unique composante) est représenté par une courbe ROC se superposant avec la première diagonale, et une valeur de AUC égale à 1/2. En pratique, on évalue souvent une version normalisée de l’AUC parfois appelée coefficient de *Gini* : $G = 2\text{AUC} - 1$. La courbe ROC est généralement située au-dessus de la première diagonale. Le coefficient de Gini correspond alors au double de l’aire entre ces deux courbes. Pour de plus amples détails sur l’évaluation des classifieurs à partir de la courbe ROC et de l’aire AUC, nous renvoyons le lecteur à [17, 18, 19, 20].

Dans le problème qui est le nôtre, $\mu : \mathcal{X} \rightarrow [0, \sup \mathcal{I}] \subseteq \mathbb{R}$ désigne (à une valeur absolue près) la transformation, caractéristique d’une approche de détection, définissant l’intensité d’une variation X , i.e. $|I| = \mu(X)$. Cette transformation dépend aussi bien du filtre dérivateur utilisé, de l’échelle(s) considérée(s), que de toute procédure sur laquelle peut reposer la caractérisation de l’intensité d’une variation (i.e. procédure de sélection ou de combinaison d’échelles).

Pour en finir avec cette section dédiée à l’évaluation, nous souhaitons faire remarquer qu’il est possible de décomposer l’erreur moyenne de classification \mathcal{E}_τ pour faire apparaître un nouveau compromis :

$$\mathcal{E}_\tau = \alpha_1^\tau (1 - l_\tau) + \pi_1 (1 - p_\tau), \quad (3.7)$$

où $l_\tau = \mathbb{P}(Y = 1 | f_\tau(X) = 1)$ croît avec τ , et $\alpha_1^\tau = \mathbb{P}(f_\tau(X) = 1)$ décroît lorsque τ croît. Nous avons choisi de faire reposer notre évaluation sur les critères présentés plus hauts, en accord avec les usages de la littérature de classification. Le développement et l’évaluation de l’approche de prédiction des variations brusques et importantes de la production que nous présentons dans le chapitre suivant, reposent en grande partie sur ce nouveau compromis.

3.3 Etude paramétrique du comportement de différents filtres de détection

Dans cette section, nous étudions les performances de détection (au sens de Canny, voir section 2.3.1 du chapitre précédent) de différents filtres rencontrés dans la littérature. Le but est ici d'analyser l'influence que peut avoir la "forme" de ces derniers sur les performances de détection des ruptures issues de notre modèle. Cette analyse passe par l'étude du comportement de chaque filtre à différentes largeurs. Ultérieurement, elle peut servir à l'élaboration à partir d'un filtre adapté, d'une ou plusieurs approches de détection multi-échelles.

3.3.1 Choix de filtres

Nous considérons 3 filtres issus de la littérature. Le premier est issu de la littérature éolienne. Il s'agit du filtre proposé dans [1], défini par l'Equation (2.1) et noté "MaxMin". Les deux autres filtres sont issus de la littérature de traitement du signal. Il s'agit du filtre de Prewitt défini par l'Equation (2.3) et noté "DOB", et de la dérivée première d'une Gaussienne (Equation (2.4)) notée "FDG". Ce dernier est le seul parmi les trois filtres considérés à être de support infini. La discrétisation numérique nous conduit néanmoins à assimiler le filtre FDG à un filtre de support fini. Dès lors qu'il s'agit de lisser un signal à l'aide d'un filtre Gaussien, tronquer le filtre à une largeur 4 fois supérieure à la valeur du paramètre de lissage est souvent jugé comme un choix raisonnable [21]. L'"étalement" plus important de sa dérivée nécessite de tronquer le filtre FDG à une largeur plus grande. Nous choisissons de tronquer ce dernier à une largeur égale à 6 fois la valeur du paramètre d'échelle s (voir Equation (2.4)). Afin d'assurer une normalisation correcte quelque soit sa largeur, nous renormalisons le filtre FDG après l'avoir tronqué et discrétisé. Dans ce qui suit, nous étudions les performances de détection des filtres FDG, DOB et MaxMin pour des largeurs de filtre allant de 20 mn à 12 h par pas de 20 mn.

3.3.2 Evaluation des performances de détection à partir des critères de Canny

Critère de détection : Ratio signal sur bruit en sortie de filtre

A travers l'estimation du ratio signal sur bruit (SNR) en sortie de filtre, on cherche à évaluer l'aptitude d'un filtre à discriminer une rupture du bruit dans un signal. La valeur de ce ratio est d'autant plus grande que l'écart entre la réponse du filtre à une rupture et sa réponse au bruit est important. Son évolution avec la largeur de filtre permet d'évaluer le compromis existant généralement entre l'atténuation du bruit d'un côté, et la limitation des interactions dans la détection de ruptures proches de l'autre. Ce compromis peut notamment être observé dans le cas des filtres DOB et FDG (voir Figure 3.5). L'augmentation de leur largeur permet, dans un premier temps, d'accroître la réponse à une rupture, tout en réduisant le bruit en

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection

sortie de filtre. On observe ainsi une augmentation du SNR en sortie de filtre. Au delà d'une certaine largeur, la présence d'autres ruptures proches limite, voire diminue, la réponse du filtre à une rupture. On observe alors une stagnation, voire un déclin, du SNR en sortie de filtre. Les performances de détection du filtre DOB sont généralement meilleures que celles du filtre FDG. Ceci s'explique par la meilleure adéquation entre la forme du filtre DOB et celle des ruptures de notre modèle. Toutefois, la forme du filtre FDG rend ce dernier moins sensible aux perturbations introduites par la présence de ruptures voisines. Les performances de détection des filtres DOB et FDG s'équilibrent ainsi dès lors que la largeur de filtre est suffisamment grande.

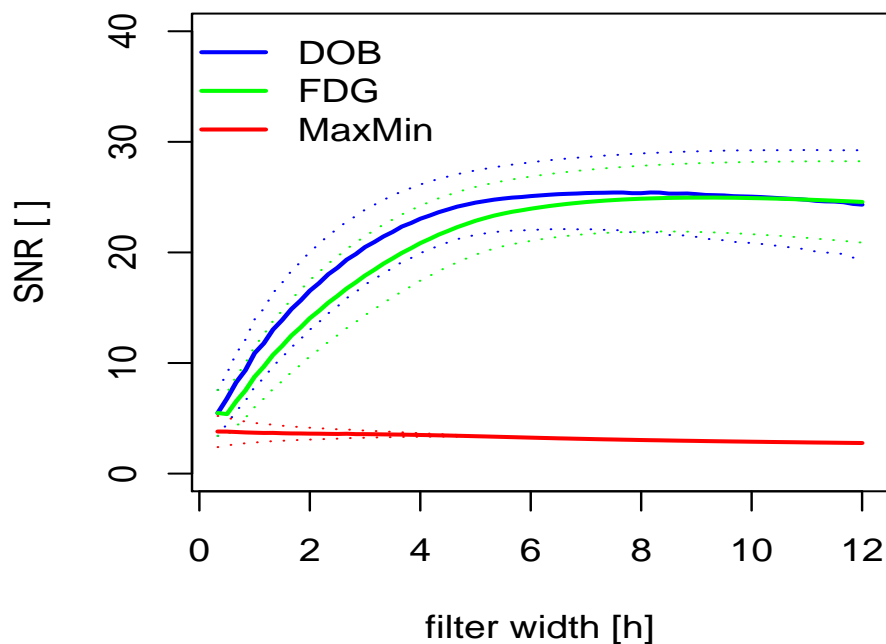


FIGURE 3.5 – Ratio signal sur bruit en sortie de filtre – Ratio moyen (lignes solides), +/- écart-type (lignes pointillées) des filtres DOB, FDG et MaxMin, en fonction de la largeur de filtre. Les largeurs considérées ici vont de 20 mn à 12 h. L'atténuation du bruit qui accompagne l'opération de lissage pratiquée par les filtres DOB et FDG, permet une rapide augmentation des performances de détection à mesure qu'augmente la largeur de filtre. La présence de ruptures proches limite la réponse à une rupture, et à terme, entraîne une stagnation du SNR en sortie de filtre. De par sa définition, la réponse au bruit du filtre MaxMin croît avec la largeur de ce dernier. Cet accroissement s'équilibre avec celui de la réponse du filtre à une rupture, et entraîne ainsi une stagnation de son SNR en sortie de filtre, et ce dès les plus petites échelles.

De par la nature particulière de sa définition, caractérisée notamment par l'absence d'opération de lissage, le filtre MaxMin ne présente pas un tel compromis. Ses performances de

détection, vis-à-vis de celles des filtres DOB et FDG, sont très nettement inférieures (voir Figure 3.5). A mesure qu'augmente sa largeur, sa réponse au bruit croît au lieu de décroître. Cette augmentation et celle de sa réponse à une rupture s'équilibrent, entraînant ainsi une stagnation de son SNR en sortie de filtre.

Critères de localisation : multiplicité des réponses et erreur de localisation

Parmi les critères proposés par Canny, les deux derniers sont destinés à évaluer les performances d'un filtre dans la localisation d'une rupture. La multiplicité des maxima due au bruit, dans la réponse d'un filtre à une rupture, complique la localisation de cette dernière. Il devient en effet impossible de distinguer lequel des différents maxima localise précisément la rupture. Cette multiplicité a tendance à disparaître à mesure qu'augmente la largeur de filtre (voir Figure 3.6, graphe de gauche). Une plus grande largeur se traduit, pour les filtres DOB et FDG, par une plus forte atténuation du bruit, et une plus faible multiplicité. Dans le cas du filtre MaxMin, cette multiplicité se trouve réduite du fait de la propension qu'a la réponse du filtre à maintenir sa valeur maximale³ (pour un exemple d'illustration voir Figure 2.7, graphe en haut à gauche). Il est parfois fait mention d'une multiplicité importante dans la réponse du filtre DOB (voir [4] et les références qui y sont citées). D'un point de vue théorique, on s'aperçoit que ce dernier ne filtre pas toujours correctement les hautes fréquences. Un moyen de s'en convaincre consiste à comparer le *gain* des filtres DOB et FDG (i.e. le module de leur transformée de Fourier [22]).

La largeur de filtre contrôle, comme pour la détection, un compromis vis-à-vis de l'erreur de localisation d'une rupture. Augmenter la largeur de filtre doit permettre dans un premier temps, par atténuation du bruit, de réduire cette erreur. Ce phénomène peut être observé pour les filtres DOB et FDG (voir Figure 3.6, graphe de droite). Au delà d'une certaine largeur, ce bénéfice est perdu devant l'effet de délocalisation produit par la présence de ruptures voisines. De par sa forme particulière, caractérisée par une pondération moindre à ses extrémités, le filtre FDG y est moins sensible que le filtre DOB. Pour ce qui est du filtre MaxMin, la propension qu'a sa réponse à maintenir une valeur maximale nécessite de définir une stratégie de localisation adaptée. Nous choisissons de localiser une rupture à partir du centre de l'intervalle pour lequel la réponse du filtre maintient sa valeur maximale. Le filtre MaxMin n'atténue pas le bruit. L'augmentation de sa largeur entraîne une rapide augmentation de l'erreur de localisation d'une rupture.

L'utilisation d'une grande largeur de filtre dans la détection de ruptures proches peut être responsable d'une importante délocalisation de la réponse d'un filtre à chacune de ces ruptures. Il en résulte parfois l'absence de réponse du filtre dans l'intervalle de temps considéré autour d'une rupture (défini par δ , voir Section 3.2.3). Il aurait été naturel d'associer à ces situations, une erreur de localisation maximale (i.e. égale à δ). Nous avons cependant choisi de

3. Typiquement, il arrive que sa réponse reste constante dans un intervalle de temps autour d'une rupture, comme celui considéré ici dans l'évaluation de l'erreur de localisation. Dans ce genre de cas, le nombre de maxima associés à une rupture a été fixé à 0, ce qui explique le nombre de maxima moyen < 1 que l'on peut observer dans la Figure 3.6 (graphe de gauche, pour des largeurs de filtre > 4 h).

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection




FIGURE 3.6 – Multiplicité des réponses et erreur de localisation – *Multiplicité des maxima dans la réponse d'un filtre à une rupture (à gauche), et (racine carré de) l'erreur quadratique moyenne de localisation (à droite), des filtres DOB, FDG et MaxMin, en fonction de la largeur de filtre. Accroître la largeur de filtre permet de réduire la multiplicité des réponses à une rupture. Dans le cas du filtre MaxMin, ceci n'est pas du à l'atténuation du bruit comme pour les filtres DOB et FDG, mais à la propension qu'a sa réponse à conserver sa valeur maximale. La sensibilité au bruit du filtre MaxMin entraîne une rapide augmentation de l'erreur de localisation d'une rupture avec la largeur de filtre. Si cette erreur diminue au-delà d'une certaine largeur de filtre, ceci est du au fait que certaines erreurs, supérieures à δ , n'ont pas été prises en compte lors du calcul de l'erreur moyenne de localisation.*

les ignorer. Ainsi, leur influence se traduit par une réduction (au lieu d'une augmentation) de l'erreur de localisation d'une rupture associée au filtre MaxMin, au-delà d'une certaine largeur de filtre. Ceci souligne finalement encore davantage les mauvaises performances de ce dernier.

Performances globales et échelle optimale de détection

La largeur de filtre maximisant une combinaison appropriée (e.g. somme, produit) des critères de performances permet de définir une largeur n_{opt} globalement optimale. Dans [7] et [8], n_{opt} correspond au double de la durée, fixe, séparant les deux ruptures de sens contraires définissant le profil de ruptures. Dans notre modèle, un accroissement plus ou moins linéaire de n_{opt} en fonction de la durée moyenne d'un épisode de production nulle λ_{T_1} , peut être observé dans le cas des filtres DOB et FDG (voir Figure 3.7). Cette tendance est associée à des valeurs de n_{opt} d'autant plus grandes qu'augmente la durée moyenne d'un épisode de production élevée (durée représentée ici par le paramètre c). Dans le cas du filtre MaxMin, n_{opt} est ici de l'ordre de 1/2 h. La sensibilité du filtre au bruit et aux perturbations introduites

par la présence de ruptures voisines, fait qu'il est généralement préférable de l'utiliser avec une largeur restreinte.

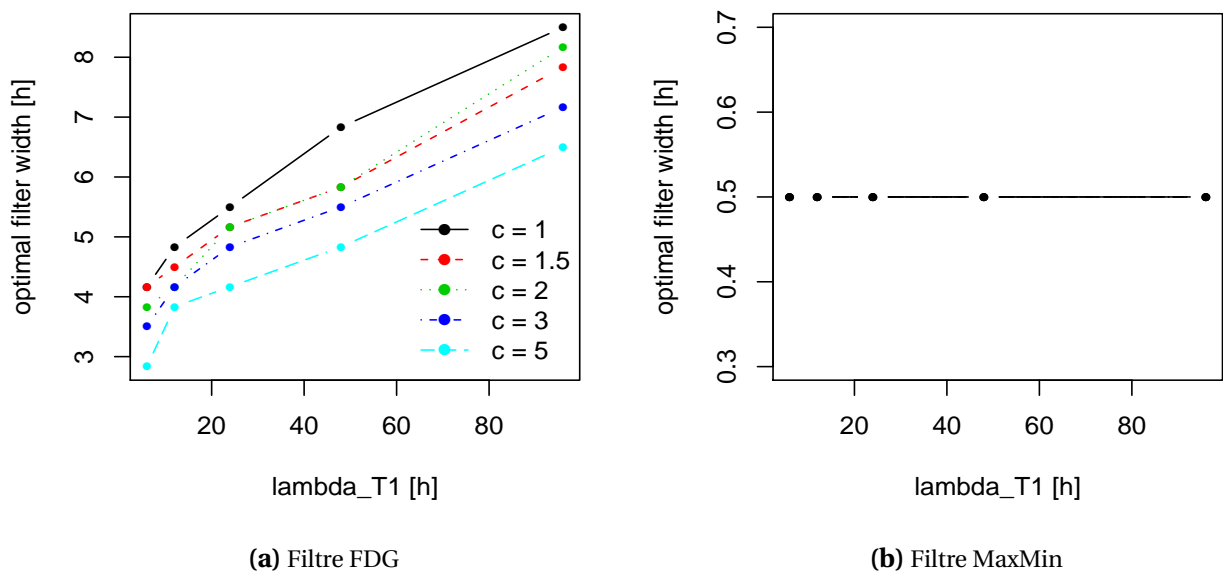


FIGURE 3.7 – Largeur de filtre globalement optimale – Largeur de filtre maximisant le produit du SNR en sortie de filtre avec l'inverse de l'erreur de localisation, pour les filtres FDG et MaxMin. Pour le filtre FDG, cette largeur croît lorsque qu'augmente la durée moyenne séparant deux ruptures consécutives (durée représentée par les paramètres λ_{T_1} et c), mais généralement pas pour le filtre MaxMin. La sensibilité de ce dernier au bruit et aux perturbations introduites par la présence de ruptures voisines, fait qu'il est généralement préférable de l'utiliser avec une largeur restreinte.

3.4 Etude paramétrique d'approches de détection multi-échelles

Dans cette section, nous étudions les performances de différentes approches multi-échelles de détection. Les approches considérées reposent sur différentes définitions des deux paramètres choisis pour caractériser une variation : son instant d'apparition et son intensité. Nous évaluons et comparons les performances de ces approches en utilisant les critères d'évaluation présentés Section 3.2. Nous cherchons notamment à établir si oui et comment, l'utilisation d'informations recueillies à différentes échelles dans la caractérisation d'une variation, permet de mieux détecter les ruptures d'un signal.

3.4.1 Approches multi-échelles

Nous considérons deux types d'approches multi-échelles. Dans le premier la caractérisation d'une variation repose sur une procédure de combinaison d'échelles, alors que dans le second elle repose sur une procédure locale de sélection d'échelle. Dans le premier type d'approches, l'intensité I et l'instant d'apparition t_I d'une variation, sont définis à partir des maxima locaux du signal f_t (en valeur absolue), issu de la combinaison (somme ou produit) des réponses d'un filtre à différentes échelles (voir Equation (2.5), Section 2.3.2). Nous désignerons respectivement ces approches (somme ou produit), par Gallego et Bao en référence aux noms des auteurs qui les ont proposées (dans resp. [3] et [9]). Dans le second type d'approches, l'intensité et l'instant d'apparition d'une variation sont définis à partir des maxima locaux du signal filtré (en valeur absolue), à une échelle choisie localement selon la procédure définie par l'Equation (2.7). Nous désignerons cette approche par Lindeberg, en référence au nom de l'auteur qui l'a proposée (voir [23, 24]).

Nous choisissons également d'étudier les performances d'une quatrième approche. Cette dernière est une approche "hybride" reposant à la fois sur une procédure de combinaison et de sélection locale d'échelle. L'instant d'apparition d'une variation y est défini de la même manière que dans l'approche Lindeberg. L'intensité d'une variation y est quant à elle définie par la valeur moyenne des intensités à différentes échelles. Cette approche s'apparente ainsi à l'approche Gallego, à la différence que la somme caractérisant l'intensité d'une variation s'effectue directement sur les maxima des réponses d'un filtre aux différentes échelles (voir aussi Section 2.3.2). Formellement, l'intensité et l'instant d'apparition d'une variation s'écrivent :

$$I = \frac{1}{s_{loc} - s_1} \int_{s_1}^{s_{loc}} I(s) ds \quad (3.8)$$

$$t_I = \underset{|t-t_1| \leq \rho_{s_{loc}}}{\operatorname{argmax}} |(h_{s_{loc}} * p)_t|$$

$$t_1 : \text{position associée au maximum } |I(s_1)| = |(h_{s_1} * p)_{t_1}|$$

$$\rho_s : \text{rayon du filtre } h_s$$

où $s_1 < s_{loc} \leq s_{max} \leq s_n$, avec s_{max} l'échelle maximale inférieure à une échelle choisie s_n , pour laquelle le signal p_t filtré avec $h_{s_{max}}$ (en valeur absolue), admet un maximum local en réponse à une variation. A condition d'utiliser un filtre causal, l'intensité d'une variation $I(s)$ à l'échelle s est ainsi définie $\forall s \in [s_1, s_{max}]$. L'échelle s_{loc} est quant à elle l'échelle maximisant l'intensité (en valeur absolue) d'une variation $|I(s)|$, telle que définie dans l'approche Lindeberg. L'algorithme utilisé afin de construire les fonctions $I(s)$ est détaillé Table 3.3. Dans l'étude qui vient, nous dénoterons l'approche de détection basée sur une telle caractérisation des variations d'un signal par TSI (pour *Time-Scale Integration*).

Certaines des approches considérées ici nécessitent l'utilisation d'un filtre causal. Dans ce qui suit, nous étudions les performances des différentes approches à partir de l'utilisation d'une transformée en ondelettes continue, avec pour ondelette mère la dérivée première

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

d'une Gaussienne. Le support de cette dernière est supposé de rayon 3, i.e. $\rho_s = 3s$. Si le choix d'une autre normalisation que celle considérée à travers l'utilisation d'une transformée en ondelettes doit avoir une influence sur les performances de certaines approches (e.g. à travers la procédure de sélection d'échelle définie dans l'approche Lindeberg), l'influence de ce choix n'est pas étudiée ici.

L'utilisation de plusieurs échelles ne départit pas du choix d'une échelle minimale, maximale, ainsi que d'un pas d'incrément de l'échelle. La plus petite échelle s_1 est définie ici par la résolution des signaux conformément au choix fait dans [3]. Le pas d'incrément de l'échelle se doit d'être suffisamment petit afin d'assurer une approximation numérique satisfaisante de I dans l'Equation (3.8). Nous considérons une valeur 3 fois inférieure à celle de la résolution des signaux. Enfin, l'échelle maximale s_n est un paramètre dont nous étudierons l'influence sur les performances des différentes approches. Nous considérons les valeurs suivantes : $s_n = 1/3, 1/2, 1, 1.5, 2, 2.5, 3$ h.

TABLE 3.3 – Algorithme de construction de $I(s)$ –

$s_1 < \dots < s_n$: échelles de détection

$M^s = \{m_1^s, \dots, m_{n_s}^s\}$: valeur signée des maxima locaux de $|(h_s * p)_t|$

t_l^s : position du maximum $|m_l^s|$

\mathcal{I} : ensemble des fonctions $I(s)$

$t_I(s)$: instant d'apparition d'une variation caractérisée à l'échelle s par l'intensité $I(s)$

ρ_s : rayon du support du filtre h_s

```

 $\mathcal{I} = \{I, I(s_1) \in M^{s_1}\}$ 
for  $k = 1 : n$ 
  for  $I \in \mathcal{I}$ 
    Soit  $l_I = \underset{1 \leq l \leq n_{s_{k+1}}}{\operatorname{argmin}} |t_l^{s_{k+1}} - t_I(s_k)|$ 
    if  $( (|t_{l_I}^{s_{k+1}} - t_I(s_k)| \leq \rho_{s_{k+1}}) \&\& (\operatorname{sign}(m_{l_I}^{s_{k+1}}) == \operatorname{sign}(I(s_1))) )$ 
       $I(s_{k+1}) = m_{l_I}^{s_{k+1}}$ 
       $t_I(s_{k+1}) = t_{l_I}^{s_{k+1}}$ 
    end if
  end for
end for

```

3.4.2 Evaluation des performances de détection et de localisation

Performances de détection

Influence de la proximité des ruptures dans un signal : L'analyse des résultats à partir de l'aire sous la courbe ROC permet d'avoir une vision globale des performances de détec-

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection

tion. Les résultats d'estimations de l'AUC, en fonction de la durée moyenne d'un épisode de production nulle λ_{T_1} et du ratio définissant la durée moyenne d'un épisode de production élevée c , sont montrés Figure 3.8. Ces derniers ont été obtenus à partir d'une valeur d'échelle maximale s_n^* garantissant les meilleures performances de détection possible, i.e. $s_n^*(\lambda_{T_1}, c) = \operatorname{argmax}_{s_n} \operatorname{AUC}(\lambda_{T_1}, c)$. Ces résultats mettent en évidence une différence notable entre les performances de détection des approches basées sur une combinaison d'échelles (i.e. Gallego et Bao), et celles des approches faisant intervenir une procédure locale de sélection d'échelle (i.e. Lindeberg et TSI). En effet, les performances de ces dernières se maintiennent, quelque soient les caractéristiques définissant la durée entre deux ruptures consécutives dans un signal. Les premières au contraire montrent des performances en déclin dès lors que diminue la durée moyenne séparant deux ruptures.

La valeur généralement élevée de l'AUC fait qu'il est difficile d'apprécier de manière quantitative l'écart de performances entre différentes approches. La comparaison de ces performances à celles obtenues à partir de l'utilisation d'une seule et même échelle globalement optimale, i.e. $s_{\text{opt}}(\lambda_{T_1}, c) = \operatorname{argmax}_s \operatorname{AUC}(\lambda_{T_1}, c)$, permet ici de mieux apprécier cet écart. Cette comparaison établit une discrimination entre approches basées sur la combinaison ou sur la sélection locale d'échelle. D'un côté, l'utilisation d'une seule et même échelle s_{opt} dans la détection de l'ensemble des ruptures d'un signal, fournit de meilleurs résultats qu'une stratégie de combinaison d'échelles comme dans l'approche Gallego (Figure 3.9, graphe de gauche). D'un autre côté, une procédure locale de sélection d'échelle comme dans l'approche Lindeberg, permet d'accroître les performances de détection vis-à-vis de l'utilisation d'une échelle globalement optimale (Figure 3.9, graphe de droite). L'hybridation des approches de sélection locale et de combinaison d'échelles (i.e. approche TSI), n'offre pas de nouveau gain de performances. Les performances intermédiaires de l'approche TSI nous amènent à penser qu'il est préférable de recueillir les informations concernant une variation à une échelle bien choisie, sans aucune forme de combinaison supplémentaire.

Dans les résultats exposés ci-dessus, le gain de performances d'une approche multi-échelle vis-à-vis d'une autre n'est effectif que si l'échelle s_n^* peut être déterminée a priori. Ceci requiert la connaissance des paramètres λ_{T_1} et c . Une estimation grossière de ces paramètres réalisée à partir de signaux réels, peut conduire à un mauvais choix dans la valeur du paramètre s_n à utiliser. Il est ainsi souhaitable pour une approche que ses performances de détection ne soit pas trop sensibles à la valeur du paramètre s_n . La Figure 3.10 montre le déclin des performances de détection des approches Gallego (graphe de gauche), et Lindeberg (graphe de droite), vis-à-vis de leurs performances optimales respectives (i.e. $\operatorname{AUC}(s_n^*)$), en fonction de la valeur de s_n . Ce déclin est représenté ici en fonction de la durée moyenne inter-ruptures (les différentes courbes correspondent aux différentes valeurs du paramètre λ_{T_1} , le paramètre c ayant été fixé à $c = 5$). Dès lors que les ruptures d'un signal sont suffisamment distantes les unes des autres, la valeur de s_n n'influe que peu sur les performances de l'approche Gallego. Cependant, si ces ruptures sont proches (i.e. $\lambda_{T_1} = 6$ h, courbe noire), le choix de s_n devient critique pour s'assurer de conserver des performances de détection proches des performances optimales. D'un autre côté, si les performances de l'approche Lindeberg appa-

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

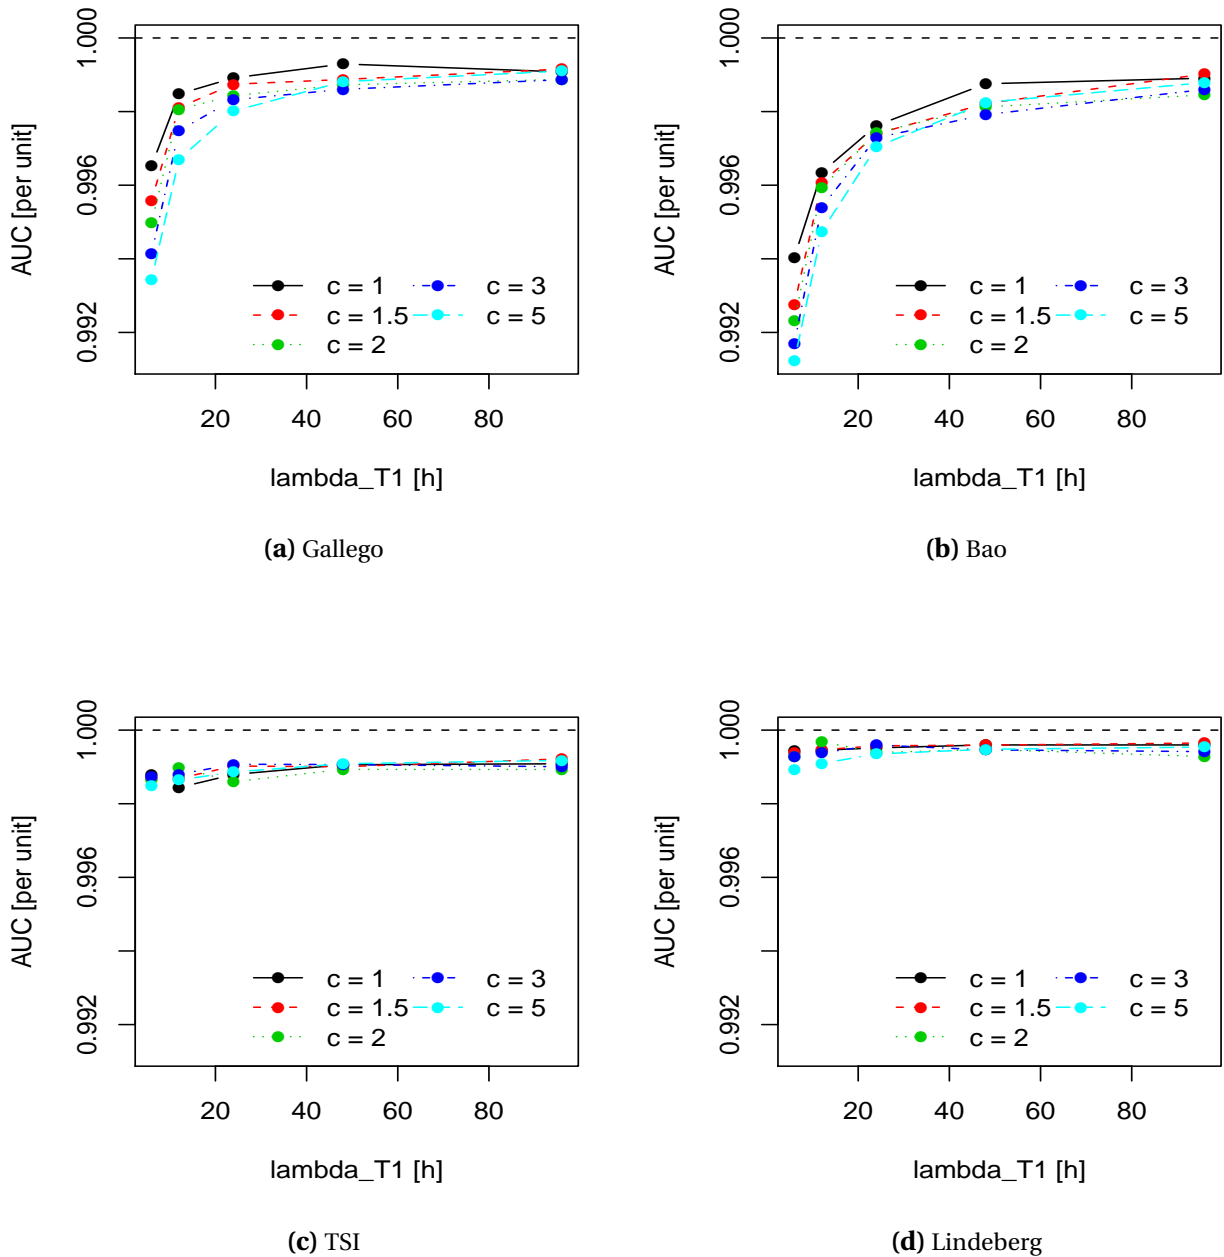


FIGURE 3.8 – Performances de détection optimales en fonction de la durée inter-ruptures – AUC maximale (i.e. pour une valeur d'échelle maximale $s_n^* = \operatorname{argmax}_{s_n} AUC(\lambda_{T_1}, c)$), représentée en fonction de la durée moyenne d'un épisode de production nulle λ_{T_1} et du ratio définissant la durée moyenne d'un épisode de production élevée c , pour les approches : Gallego, Bao, TSI et Lindeberg. Alors que les performances des approches faisant intervenir une procédure locale de sélection d'échelle (i.e. Lindeberg et TSI) se maintiennent, celles des approches basées sur une combinaison d'échelles (i.e. Gallego et Bao) déclinent lorsque diminue la durée moyenne inter-ruptures.

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection




FIGURE 3.9 – Performances de détection : comparaison approches uni- et multi-échelles – Accroissement de l'AUC maximale ($s_n = s_n^*$) des approches Gallego (à gauche) et Lindeberg (à droite), vis-à-vis de l'AUC obtenue par une approche basée sur l'utilisation d'une échelle globalement optimale (i.e. $s_{opt} = \operatorname{argmax}_s AUC(\lambda_{T_1}, c)$). On observe bien ainsi (et plus particulièrement dans le cas de ruptures proches), comment une approche de détection basée sur une procédure de sélection d'échelle, même globale, permet d'obtenir de meilleures performances de détection qu'une approche basée sur une combinaison d'échelles.

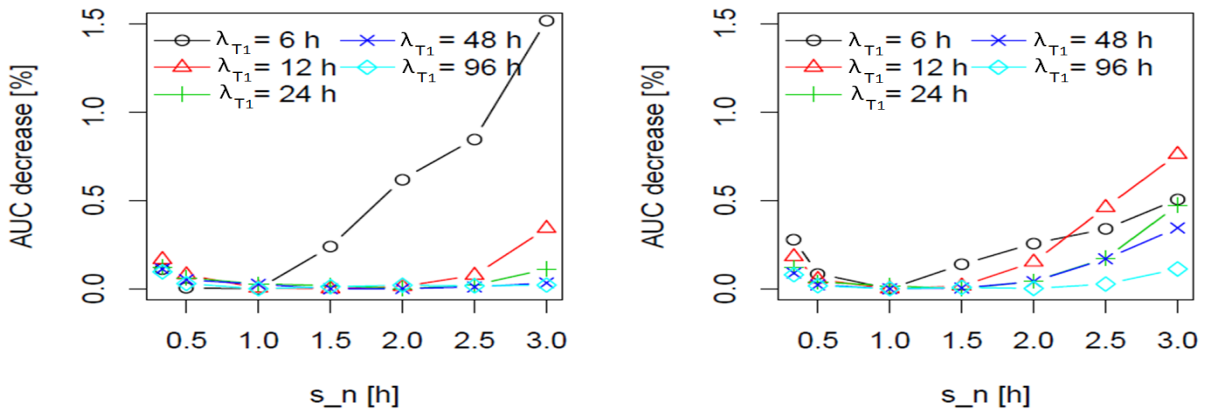


FIGURE 3.10 – Sensibilité des performances de détection au choix de s_n – Déclin des performances de détection vis-à-vis des performances optimales (i.e. $AUC(s_n^*)$), pour les approches Gallego (à gauche), et Lindeberg (à droite), en fonction de la valeur de s_n . Les performances de l'approche Gallego, qui apparaissent moins sensibles à la valeur de s_n que les performances de l'approche Lindeberg, le sont plus dès lors que la durée moyenne inter-ruptures est petite (i.e. $\lambda_{T_1} = 6$ h, courbe noire). Les résultats présentés ici ont été obtenus pour un ratio $c = 5$ entre la durée moyenne d'un épisode de production nulle, et la durée moyenne d'un épisode de production élevée.

raissent de manière générale plus sensibles au choix de s_n , cette sensibilité reste davantage contenue dès lors que la durée moyenne séparant deux ruptures devient plus faible.

Influence du ratio signal sur bruit – le cas de ruptures proches : A travers une courbe ROC, on peut observer le compromis qu’une approche de détection établit entre deux types d’erreur de classification. D’une part, l’erreur qui consiste à classer une variation due au bruit comme une rupture. D’autre part, l’erreur qui consiste à classer une rupture comme une variation due au bruit. Les résultats obtenus par les quatre approches considérées, pour des valeurs de paramètres définissant des ruptures proches, $\lambda_{T_1} = 6$ h et $c = 5$, d’amplitude $A = 50\% P_n$, de durée moyenne $\lambda_{T_2} = 3$ h et pour une forte intensité de bruit $j = 2$, sont montrés Figure 3.11. La valeur du paramètre s_n a été fixée en conséquence, i.e. $s_n = s_n^*$. Le bon potentiel de discrimination des ruptures d’une approche, est représenté par une courbe ROC à l’aspect coudé, proche du coin situé en haut à gauche de la figure. Les valeurs d’intensité

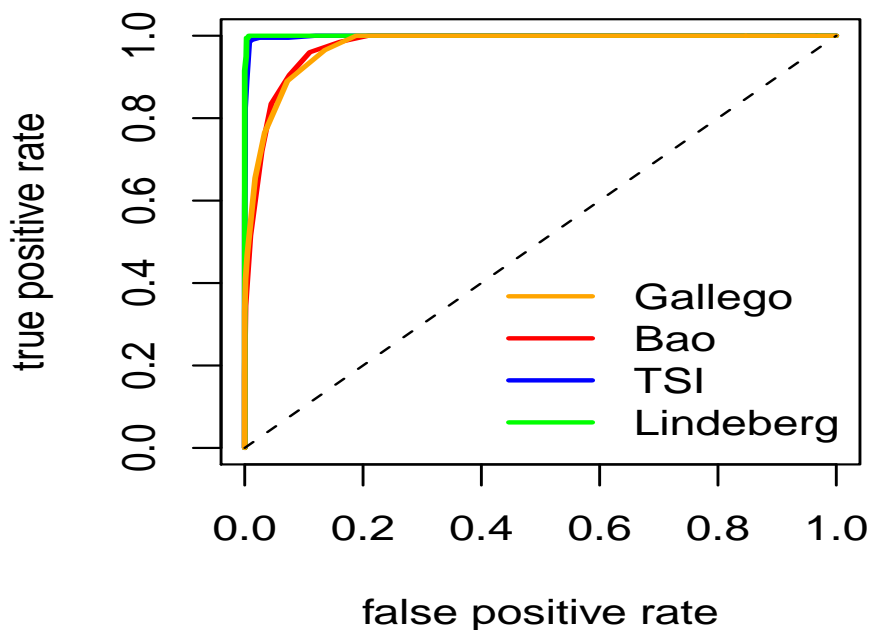


FIGURE 3.11 – Courbe ROC – Représentation du compromis existant entre les deux types d’erreur de classification des variations d’un signal pour les approches Bao, Gallego, TSI et Lindeberg. La proximité des courbes bleue et verte (superposées) avec le coin supérieur gauche de la figure montre l’aptitude des approches TSI et Lindeberg à classer parfaitement ou presque les variations d’un signal. Les résultats montrés ici ont été obtenus pour des valeurs de paramètres définissant des ruptures proches $\lambda_{T_1} = 6$ h et $c = 5$, d’amplitude $A = 50\% P_n$ et de durée moyenne $\lambda_{T_2} = 3$ h, et pour une forte intensité de bruit $j = 2$. La valeur d’échelle maximale a quant à elle été fixée à $s_n = s_n^*$.

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection

seuils autorisant une classification parfaite des variations sont représentées par des points situés dans ce même coin. Dans un cas tel que celui présenté Figure 3.11, les approches TSI et Lindeberg (leurs courbes ROC se superposent dans la figure) autorisent une classification parfaite ou presque des variations d'un signal de production simulé à partir de notre modèle de rupture.

Les caractéristiques des distributions des valeurs d'intensité, associées à chaque classe de variations, permettent de mieux apprécier les résultats de cette classification. Les estimations des valeurs d'intensité moyennes \bar{I}_0 et \bar{I}_1 et des écart-types $\hat{\sigma}_0$ et $\hat{\sigma}_1$, associées à chaque classe de variations, permettent de définir un indice représentatif de la "distance" séparant ces distributions $\mathcal{S} = (\bar{I}_1 - \bar{I}_0)/(\hat{\sigma}_1^2 + \hat{\sigma}_0^2)^{1/2}$. Plus la valeur de cet indice est proche de 0, plus la "séparation" entre les deux distributions est faible. Dans la table 3.4 sont montrées des estimations obtenues dans le cas de ruptures proches ($\lambda_{T_1} = 6$ h et $c = 5$), pour différentes valeurs d'amplitude A et de durée moyenne λ_{T_2} d'une rupture, ainsi que différentes catégories j de bruit. L'association de différentes amplitudes et durées moyennes d'une rupture, avec différentes intensités de bruit, peut être assimilée à différents ratios signal-sur-bruit. Les performances de détection d'une approche sont d'autant meilleures qu'augmente le ratio signal-sur-bruit. Certaines des approches de détection considérées ici sont très sensibles à ce dernier. On s'aperçoit ainsi que les approches Bao et Gallego offrent un bon potentiel de discrimination des ruptures d'un signal dès lors que ce ratio est élevé (i.e. pour de grandes valeurs de A , associées à de petites valeurs de λ_{T_2} et j), même lorsque les ruptures d'un signal sont proches. En revanche, les performances de ces approches déclinent fortement dès lors que diminue la valeur du ratio signal-sur-bruit. D'un autre côté, les approches TSI et Lindeberg sont moins sensibles à ce ratio, et révèlent de meilleures performances pour les cas de détection les plus difficiles (voir Table 3.4, (c)).

Performances de localisation

En marge des performances de détection, nous avons également étudié les performances de localisation d'une rupture par les différentes approches multi-échelles. Toutes ces approches bénéficient de performances de localisation d'autant meilleures qu'augmente la durée moyenne séparant deux ruptures consécutives. Ces résultats sont toutefois en contraste avec ceux obtenus en terme de détection. La Figure 3.12 montre la réduction de (la racine carré de) l'erreur quadratique moyenne de localisation d'une rupture, obtenue par les approches Gallego (graphe de gauche) et Lindeberg (graphe de droite) vis-à-vis d'une approche "uni-échelle", en fonction des paramètres λ_{T_1} et c . Les résultats montrés ici ont été obtenus à partir d'une valeur d'échelle maximale s_n optimale d'un point de vue de la localisation. Pour des ruptures proches, c'est cette fois l'approche Gallego qui bénéficie des meilleures performances de localisation (supérieures entre 5% et 10% environ à celles obtenues avec une échelle). D'un autre côté, les performances de l'approche Lindeberg sont similaires aux performances de référence. La tendance s'inverse quelque peu dès lors qu'augmente la durée moyenne inter-ruptures. Les performances de l'approche Bao (inférieures), et celles de l'approche TSI (similaires à celles de l'approche Lindeberg), ne sont pas montrées ici.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

TABLE 3.4 – Caractéristiques des distributions des valeurs d'intensité associées à chaque classe de variations – Estimations des valeurs d'intensité moyennes \bar{I}_0 et \bar{I}_1 et des écart-types $\hat{\sigma}_0$ et $\hat{\sigma}_1$, associées à chaque classe de variations. Ces estimations s'expriment ici en $\%P_n \cdot \sqrt{h}$, P_n désignant la valeur de production nominale, du fait de l'utilisation d'une transformée en ondelettes continue. L'indice $S = (\bar{I}_1 - \bar{I}_0) / (\hat{\sigma}_1^2 + \hat{\sigma}_0^2)^{1/2}$ quantifie la "distance" séparant les distributions associées à chaque classe de variations. Les résultats montrés ici ont été obtenus pour une valeur d'échelle maximale $s_n = s_n^*$, des valeurs de paramètres décrivant des ruptures proches, $\lambda_{T_1} = 6$ h et $c = 5$, de différentes amplitudes A et durées moyennes λ_{T_2} , ainsi que pour différentes catégories de bruit j . L'association de ces trois derniers paramètres définit un ratio signal-sur-bruit ((a), (b) et (c) décrivent des ratios de plus en plus faibles). Si les approches Gallego et Bao offrent un bon potentiel de discrimination des ruptures d'un signal dès lors que ce ratio est élevé, leurs performances déclinent fortement lorsqu'il diminue. D'un autre côté, les approches TSI et Lindeberg révèlent des performances supérieures dans les cas de détection les plus difficiles (e.g. (c)).

(a) $A = 100\% P_n, \lambda_{T_2} = 10$ mn, $j = 1$

	\bar{I}_1 [$\%P_n \cdot \sqrt{h}$]	\bar{I}_0 [$\%P_n \cdot \sqrt{h}$]	$\hat{\sigma}_1$ [$\%P_n \cdot \sqrt{h}$]	$\hat{\sigma}_0$ [$\%P_n \cdot \sqrt{h}$]	S []
Gallego	62.9	1.2	5.5	0.8	11.2
Bao	51.6	1.4	1.6	0.9	27.3
TSI	60.4	1.8	8.1	0.9	7.2
Lindeberg	75.3	2.0	4.7	2.5	13.7

(b) $A = 70\% P_n, \lambda_{T_2} = 1$ h, $j = 1$

	\bar{I}_1 [$\%P_n \cdot \sqrt{h}$]	\bar{I}_0 [$\%P_n \cdot \sqrt{h}$]	$\hat{\sigma}_1$ [$\%P_n \cdot \sqrt{h}$]	$\hat{\sigma}_0$ [$\%P_n \cdot \sqrt{h}$]	S []
Gallego	43.0	1.7	6.7	3.1	5.6
Bao	28.7	2.3	8.3	3.0	3.0
TSI	41.8	1.9	8.0	1.3	4.9
Lindeberg	59.4	2.1	5.1	1.9	10.6

(c) $A = 50\% P_n, \lambda_{T_2} = 3$ h, $j = 2$

	\bar{I}_1 [$\%P_n \cdot \sqrt{h}$]	\bar{I}_0 [$\%P_n \cdot \sqrt{h}$]	$\hat{\sigma}_1$ [$\%P_n \cdot \sqrt{h}$]	$\hat{\sigma}_0$ [$\%P_n \cdot \sqrt{h}$]	S []
Gallego	22.2	5.4	6.1	5.3	2.1
Bao	14.4	3.9	4.9	2.9	1.8
TSI	21.4	3.7	6.7	2.1	2.5
Lindeberg	34.7	4.1	6.6	2.8	4.2

Le choix d'une valeur d'échelle maximale s_n est rendu difficile du fait qu'une valeur adaptée selon un critère de détection, ne l'est pas nécessairement en terme de localisation. La Figure 3.13 montre l'augmentation en fonction de s_n de l'erreur de localisation d'une rupture vis-à-vis des performances optimales, pour les approches Gallego (à gauche) et Lindeberg (à droite). Cette augmentation est également représentée en fonction de la durée moyenne séparant deux ruptures (les différentes courbes correspondent aux différentes valeurs du paramètre λ_{T_1} , le paramètre c lui a été fixé à $c = 2$). L'augmentation importante de l'erreur

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection

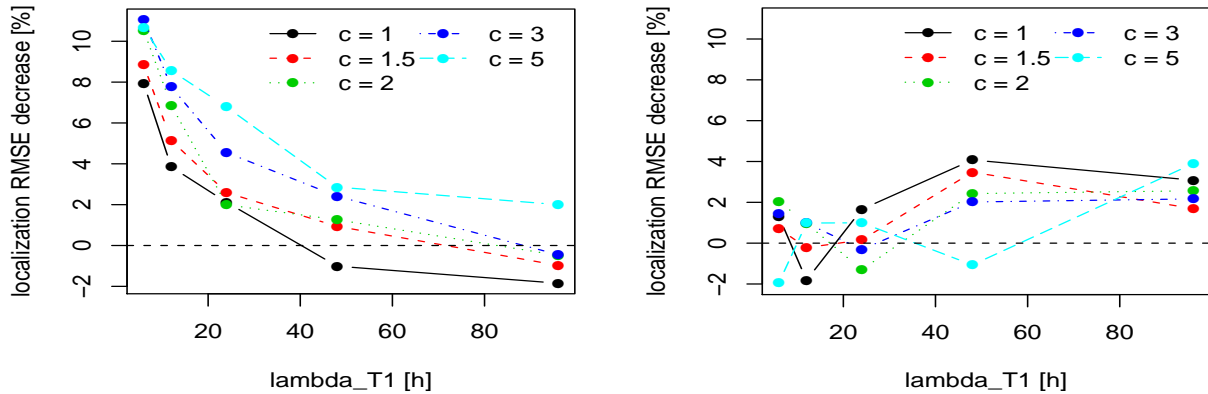


FIGURE 3.12 – Performances de localisation et durée inter-ruptures : comparaison approches uni- et multi-échelles – Réduction de (la racine carré de) l'erreur quadratique moyenne de localisation d'une rupture pour les approches Gallego et Lindeberg (resp. à gauche et à droite), vis-à-vis de l'utilisation d'une unique échelle globalement optimale, en fonction des paramètres λ_{T_1} et c . Ces résultats sont en contraste avec ceux obtenus pour la détection, puisque c'est l'approche de combinaison d'échelles Gallego qui obtient de meilleures performances que l'approche Linderberg, dès lors que les ruptures d'un signal sont proches. La tendance s'inverse toutefois quelque peu dès lors que la durée moyenne inter-ruptures augmente.

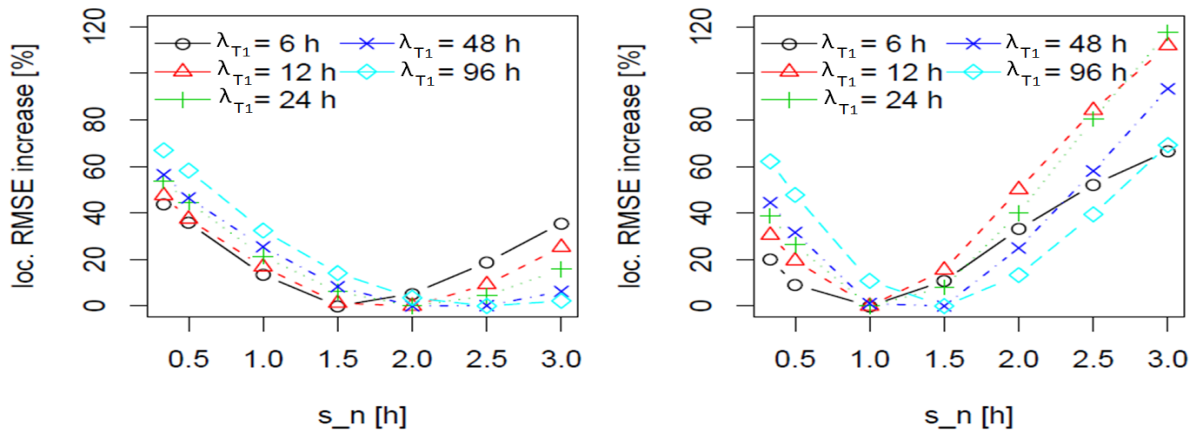


FIGURE 3.13 – Sensibilité des performances de localisation au choix de s_n – Déclin des performances de localisation vis-à-vis des performances optimales, pour les approches Gallego (à gauche), et Lindeberg (à droite), en fonction de la valeur de s_n . Les performances de l'approche Gallego sont cette fois encore moins sensibles à la valeur de s_n , que les performances de l'approche Lindeberg. Toutefois, en comparant avec la Figure 3.10, on observe chez cette dernière une meilleure adéquation entre les valeurs de s_n permettant d'optimiser respectivement la détection et la localisation d'une rupture. Les résultats présentés ici ont été obtenus pour un ratio $c = 5$ entre la durée moyenne d'un épisode de production nulle, et la durée moyenne d'un épisode de production élevée.

de localisation pour certaines valeurs de s_n est à relativiser, les performances optimales faisant état d'une erreur de localisation n'excédant pas 1/4 h environ alors que la résolution des signaux est fixée à 10 mn. Ceci explique pourquoi les performances de localisation apparaissent comme beaucoup plus sensibles au choix de s_n , que ne le sont les performances de détection. L'évolution de l'erreur de localisation en fonction de s_n permet néanmoins de constater certains faits intéressants. Dans le cas de l'approche Lindeberg, les valeurs de s_n autorisant une faible erreur de localisation se concentrent autour des valeurs $s_n = 1$ h et 1.5 h. Ces valeurs semblent particulièrement adaptées puisqu'elles autorisent également de bonnes performances de détection (voir Figure 3.10). Dans le cas de l'approche Gallego, il est plus difficile de faire un choix de s_n qui soit à la fois satisfaisant en terme de détection et de localisation. En effet, si de faibles valeurs de s_n (e.g. $s_n = 0.5$ h ou 1 h) sont adaptées en terme de détection, il est nécessaire de faire appel à des valeurs plus grandes (e.g. entre 1.5 h et 2 h) afin d'optimiser les performances de localisation.

3.5 Conclusions

Dans la littérature éolienne, l'étude des variations brusques et importantes de la production a vu l'apparition de nouvelles approches de caractérisation et de détection de ces variations. A notre connaissance, il n'existe pas de travaux évaluant ces approches à partir de critères quantitatifs tangibles, permettant ainsi d'établir le bien fondé de ces approches. La nature formelle des caractères brusque et important d'une variation, ainsi que l'adéquation de ces approches dans leur caractérisation, n'ont jamais été précisées. Dans ce chapitre nous avons proposé un cadre d'évaluation à partir duquel ces approches peuvent être étudiées. Nous y avons défini de manière formelle les caractères brusque et important d'une variation. Nous y avons également décrit des critères quantitatifs permettant d'évaluer objectivement une approche dans la caractérisation qu'elle fait des ruptures issues de notre modèle.

Le modèle de rupture que nous avons proposé reprend certains aspects essentiels des modèles rencontrés dans la littérature de détection de ruptures. Nous avons poussé plus loin leur modélisation afin de représenter adéquatement certaines propriétés du processus de production. En modélisant la durée séparant deux ruptures consécutives par des variables aléatoires, nous avons reproduit le caractère aléatoire avec lequel ces dernières se succèdent dans un signal de production. A travers la modélisation du bruit, nous nous sommes attachés à reproduire certains aspects du caractère non-stationnaire et borné du processus de production. A côté de ça et en marge des critères de Canny [4], nous avons proposé des critères issus de la littérature de classification, permettant d'évaluer les performances de détection d'une approche.

A partir du modèle de rupture et des critères d'évaluation proposés, nous avons étudié différents filtres et approches de détection rencontrés dans la littérature éolienne. Nous avons comparé leurs performances à celles d'autres filtres et approches issus de la littérature de détection de ruptures. Les résultats issus de notre modèle ont montré que le filtre proposé

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection

dans [1] était très sensible au bruit, et présentait des performances inférieures à celles de filtres usuels de détection. Nous avons également étudié les performances de différentes approches multi-échelles de détection. Les résultats issus de notre modèle ont montré qu'une stratégie reposant sur la combinaison d'informations à différentes échelles comme c'est le cas dans [3] ou dans [9], n'était pas optimale en terme de performances de détection. Dans un signal où la durée inter-ruptures évolue aléatoirement encore que de manière stationnaire, l'utilisation d'une unique échelle globalement optimale permet d'obtenir de meilleures performances. Une stratégie reposant sur une procédure locale de sélection d'échelle comme celle proposée dans [23], permet d'obtenir des performances encore meilleures. D'un autre côté, l'approche proposée dans [3] permet de mieux localiser les ruptures proches issues de notre modèle, pourvu que ces dernières aient été détectées.

Il serait intéressant d'étudier si les mêmes résultats ressortent d'une étude où la durée aléatoire séparant deux ruptures consécutives est modélisée de manière non-stationnaire. Il serait ainsi possible d'étudier l'influence sur les performances de détection d'une approche, de potentielles variations diurnes ou saisonnières dans l'évolution de la durée moyenne séparant les ruptures d'un signal de production. Ceci peut être fait à partir de quelques modifications réalisées sur notre modèle de rupture, et à partir des critères d'évaluation que nous avons introduits.

Bibliographie

- [1] N.J. Cutler, M. Kay, K. Jacka, and T.S. Nielsen. Detecting, categorizing and forecasting large ramps in wind farm power output using meteorological observations and WPPT. *Wind Energy*, 10(5) :453–470, 2007.
- [2] B. Greaves, J. Collins, J. Parkes, and A. Tindal. Temporal Forecast Uncertainty for Ramp Events. *Wind Engineering*, 33(11) :309–319, 2009.
- [3] C. Gallego, A. Costa, Á. Cuerva, L. Landberg, B. Greaves, and J. Collins. A wavelet-based approach for large wind power ramp characterisation. *Wind Energy*, pages n/a–n/a, 2012. DOI : 10.1002/we.550.
- [4] J. Canny. A computational approach to edge detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-8(6) :679–698, 1986.
- [5] S. Mallat and S. Zhong. Characterization of signals from multiscale edges. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 14(7) :710–732, jul 1992.
- [6] C. Ducottet, T. Fournel, and C. Barat. Scale-adaptive detection and local characterization of edges based on wavelet transform. *Signal Processing*, 84(11) :2115–2137, 2004.
- [7] D. Demigny. On optimal linear filtering for edge detection. *Image Processing, IEEE Transactions on*, 11(7) :728–737, 2002.
- [8] O. Laligant, F. Truchetet, and F. Meriaudeau. Regularization preserving localization of close edges. *Signal Processing Letters, IEEE*, 14(3) :185–188, march 2007.
- [9] P. Bao, L. Zhang, and X. Wu. Canny edge detection enhancement by scale multiplication. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 27(9) :1485–1490, sept. 2005.
- [10] J.H. Elder and S.W. Zucker. Local scale control for edge detection and blur estimation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 20(7) :699–716, jul 1998.
- [11] Y.H. Wan and D.Jr. Bucaneg. Short-term power fluctuations of large wind power plants. *Journal of Solar Energy Engineering*, 124(4) :427–431, 2002.
- [12] H. Bludszuweit, J.A. Dominguez-Navarro, and A. Llombart. Statistical analysis of wind power forecast error. *Power Systems, IEEE Transactions on*, 23(3) :983–991, aug. 2008.
- [13] P. Pinson. Very-short-term probabilistic forecasting of wind power with generalized logit - normal distributions. *Journal of the Royal Statistical Society : Series C (Applied Statistics)*, 61(4) :555–576, 2012.
- [14] A. Lau and P. McSharry. Approaches for multi-step density forecasts with application to aggregated wind power. *The Annals of Applied Statistics*, 4(3) :1311–1341, 2010.
- [15] P.G. Leahy and E.J. McKeogh. Persistence of low wind speed conditions and implications for wind power variability. *Wind Energy*, pages n/a–n/a, 2012. DOI : 10.1002/we.1509.

Modélisation des variations brusques et importantes de la production éolienne et étude paramétrique d'approches de détection

- [16] T. Hastie, R. Tibshirani, and J. Friedman. *The elements of statistical learning, second edition : Data mining, inference, and prediction*. Springer Series in Statistics. Springer, 2nd ed. 2009. corr. 3rd printing edition, 2009.
- [17] T. Fawcett. An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8) :861 – 874, 2006.
- [18] D.J. Hand. Measuring classifier performance : a coherent alternative to the area under the ROC curve. *Machine Learning*, 77 :103–123, 2009.
- [19] C. Cortes and M. Mohri. Confidence intervals for the area under the ROC curve. In *Advances in Neural Information Processing Systems (NIPS 2004)*, volume 17. MIT Press, 2005.
- [20] C. Marzban. The ROC curve and the area under it as performance measures. *Weather and Forecasting*, 19 :1106–1114, 2004.
- [21] D. Demigny, L. Kessal, and J. Pons. Fast recursive implementation of the Gaussian filter. In *11th IFIP International Conference on Very Large Scale Integration*, number 1, pages 339–346, Montpellier, France, december 2001. LIRMM.
- [22] G. Blanchet and M. Charbit. *Traitement numérique du signal*. Hermes, 1998.
- [23] T. Lindeberg. Edge detection and ridge detection with automatic scale selection. *International Journal of Computer Vision*, 30(2) :117–154, 1998.
- [24] T. Lindeberg. Feature detection with automatic scale selection. *International Journal of Computer Vision*, 30(2) :79–116, 1998.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

Chapitre 4

Estimation de l'incertitude temporelle dans la prédiction des variations brusques et importantes de la production éolienne

Première partie : Introduction

Ce chapitre est consacré à la deuxième partie de notre travail et traite des aspects relatifs à la prédiction des variations brusques et importantes de la production éolienne. Comme expliqué dans le chapitre d'introduction, la prédiction de la production à des horizons supérieurs à quelques heures nécessite l'utilisation de prévisions météorologiques. Ces dernières sont souvent responsables d'erreurs dans la prédiction de l'instant d'apparition des variations brusques et importantes de la production, synonymes d'importants déséquilibres énergétiques entre la production prédite et observée. Les approches usuelles de prédiction s'attachent généralement à estimer l'incertitude associée à des prédictions du niveau de production fournies horizon par horizon. Il s'agit ainsi d'estimations de la distribution marginale du niveau de production à différents instants. La structure temporelle entre les prédictions associées à des horizons successifs n'est ainsi dictée que par les prévisions météorologiques utilisées en entrée des modèles, et source des erreurs mentionnées.

Dans l'article ci-dessous, l'approche que nous présentons vise à estimer l'incertitude associée à la prédiction de l'instant d'apparition d'une rupture dans un signal de production. Par l'utilisation de prévisions météorologiques ensemblistes, on cherche à exploiter les différentes prédictions de cet instant que fournissent les membres d'un ensemble. Notre approche s'assimile à un post-traitement des prévisions météorologiques regroupant les opérations : de conversion en puissance, de caractérisation et de détection des ruptures, d'agrégation des prédictions de ces dernières faites par les différents membres d'un ensemble, avant

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

de finalement estimer l'incertitude temporelle sous forme de probabilités associées à des intervalles temporels. Faute de place, certains résultats n'ont pu être donnés dans l'article. Nous nous sommes limités aux résultats liés à l'estimation de l'incertitude associée à la prédiction de l'instant d'apparition d'une rupture. Afin d'offrir une présentation plus complète de notre approche, nous donnons les résultats liés à la prédiction de cet instant dans la troisième partie de ce chapitre. Les résultats obtenus à partir de données provenant d'autres fermes éoliennes ont quant à eux été renvoyés en Annexe A.

L'approche telle qu'elle est présentée dans l'article s'appuie sur une caractérisation des ruptures d'un signal de production issue d'un filtrage dérivatif effectué à une échelle. L'utilisation d'une approche multi-échelle de caractérisation pourrait néanmoins être envisagée. Nous discutons des développements qui peuvent être apportés à notre approche dans le chapitre de conclusion.

Deuxième partie : Forecasting ramps of wind power production with numerical weather prediction ensembles

Arthur Bossavy, Robin Girard et Georges Kariniotakis

Soumis au journal "**Wind Energy**" le 18/02/2011, révisé le 02/08/2011, accepté le 05/09/2011. DOI : 10.1002/we.526.

Abstract

Today, there is a growing interest in developing short-term wind power forecasting tools able to provide reliable information about particular, so-called "extreme" situations. One of them is the large and sharp variation of the production a wind farm can experience within a few hours called *ramp event*. Developing forecast information specially dedicated to ramps is of primary interest both because of the difficulties usual models have to predict them, and the potential risk they represent in the management of a power system. First, we propose a methodology to characterize ramps of wind power production with a derivative filtering approach derived from the edge detection literature. Then, we investigate the skill of numerical weather prediction ensembles to make probabilistic forecasts of ramp occurrence. Through conditioning probability forecasts of ramp occurrence to the number of ensemble members forecasting a ramp in time intervals, we show how ensembles can be used to provide reliable forecasts of ramps with sharpness. Our study relies on 18 months of wind power measures from a 8 MW wind farm located in France and forecasts ensemble of 51 members from the Ensemble Prediction System (EPS) of the European Center for Medium-Range Weather Forecasts (ECMWF).

4.1 Introduction

Wind energy is the fastest growing renewable energy source in the world. The total installed capacity has increased impressively during the last decade, passing from 10 GW in 1998 to 158 GW in 2009¹. This is an encouraging development if we consider the issue of managing power systems with high penetration of wind power. Indeed, the variable nature of wind generation makes it difficult to reach the basic requirement of balancing the electricity demand by an equal production. Short-term forecasts of wind power production up to 2 or 3 days ahead can facilitate the management of power systems by operators. Wind power forecasts are useful for performing various power system management functions, like the dynamic quantification of reserves or the optimization of combined wind-hydro power plant scheduling [1, 2]. They also prove valuable when incorporated into bidding strategies for participating in electricity markets [3, 4].

1. <http://www.ewea.org>

Most existing wind power forecasting models are designed to provide point forecasts of expected future wind farm production. In recent years, research work has focused on associating uncertainty estimation with this type of point forecast. New forecasting approaches (often called probabilistic forecasting methods) have recently emerged that provide estimations of the entire distribution of future production. In such methods, forecasts may take the form of either quantile estimations [5, 6, 7] or density estimations [8, 9]. Two extensive reviews of the state of the art in wind power forecasting are given in [10, 11].

Nowadays, wind power forecasting systems are used operationally by end-users. It is increasingly apparent, however, that current forecasting technology cannot properly handle extreme situations related to wind generation. Extreme situations may take different forms, corresponding either to extreme weather phenomena or to critical periods for power system operation [12]. An example is the steep and high increase or drop in production that a wind farm can experience in the space of a few hours, commonly known as a *ramp event*. Operational systems' performance in forecasting large variations of wind power production is often reported to be significantly lower than usual [13, 14]. This means that we either need to improve forecasting tools' performance in these situations, or develop new dedicated forecasting tools. This paper investigates the development of a new tool to forecast ramps and the associated uncertainty.

In literature related to wind energy, the term “ramp” may refer to wind power variations taking place over different time scales. It sometimes refers to intra-hourly variations, e.g. 10 to 60 minute variations [15, 16, 17]. In this paper, we use it to refer to significant changes in wind generation over one or several hours. An accurate prediction of this type of variation for the next few hours up to several days ahead therefore relies on weather forecasts provided by Numerical Weather Prediction (NWP) models [13, 14, 18]. Making a reliable forecast of exactly when such events will occur is a significant challenge. Indeed, errors in predicting the underlying weather conditions made by NWP models often result in inaccurate forecasting of ramp timing [19]. An error in forecasting ramp timing is referred to as a *phase error*. There is a growing interest in developing forecasting approaches dedicated to ramps. A survey of these approaches is presented in [20].

The way standard forecasting approaches provide uncertainty estimations cannot be adapted when focusing on the temporal uncertainty of ramp events. For instance, prediction intervals are commonly provided on a per-horizon basis, and are dedicated to uncertainty estimations associated to power level forecasts (see [21] for instance). While such forecasts may be easily integrated into a decision-making process, they do not provide an explicit estimation of the temporal uncertainty associated with a particular ramp event. Pioneer work in [19] associates an estimation of the phase error distribution with point forecasts of wind power production. These estimations take the form of a probability density function with finite support. This kind of support is designed to contain all ramps. However, evaluation results indicate poor reliability since numerous ramps are observed outside the support. Another limitation of the methodology in [19] is the unconditional estimation of the phase error distribution.

In this paper, we propose to forecast ramps on the basis of a specific timing, plus the probability of observing a ramp within a set of time intervals (hereafter referred to as “prediction intervals”) centered on that timing. Thus, our approach aims at providing a suitable uncertainty estimation associated with the forecast of a ramp timing. The proposed methodology relies on numerical weather prediction ensembles. Ensembles are alternative numerical weather predictions that are produced by perturbing the initial conditions, or a different parameterization of a numerical weather prediction model. The unperturbed prediction is referred to as control forecast and, in general, provides the most accurate wind production forecasts. Ensembles have already been used to derive probabilistic forecasts of wind generation [22, 23], and to assess future large-scale weather patterns [24]. Forecasts of wind power variations made by high-resolution ensembles have been evaluated to some extent in offshore conditions [25]. They have also been considered in a prototype ramp forecasting system [26]. In the latter, NWP ensembles are used to derive hourly distribution forecasts of wind generation. Then, statistical random sampling on two consecutive distribution forecasts makes it possible to estimate the distribution of production changes from one hour to the next. The main limitation of this methodology is that the correlation between two consecutive wind generation distribution forecasts is not properly captured, resulting in unrealistic forecasts of hourly wind power changes. The methodology proposed here is completely different, since it is based on collecting ramp forecasts from the members of the wind power ensembles. These forecasts are then clustered into coherent groups, each of them resulting in a unique forecast event. The use of the ensembles from an event-based point of view allows us to go further in evaluating the merits of the ensembles themselves as weather forecast products [27].

The paper is organized as follows. In Section 4.2, we discuss the definition of a ramp and introduce a methodology to detect and characterize a ramp event from a wind power time series. The definition proposed relies on considerations from the signal processing field and uses a filtering/thresholding approach. In Section 4.3, we start by discussing how to identify a forecast ramp event among an ensemble of wind power forecast time series. Then, we introduce the proposed ramp forecasting methodology. Section 4.4 gives an evaluation of the proposed methodology. Conclusions and perspectives are given in Section 4.5.

4.2 Definition and characterization of a ramp event

In the related literature, a change in wind power production is considered as a ramp if it exceeds a given threshold in a period shorter than a given maximum duration. This threshold is sometimes expressed as a percentage of the nominal capacity of the wind farm. Thus, detecting a ramp relies on computing the difference between the minimum and maximum production during the considered period. This computing approach seems to be followed by [13, 14, 19], where it is explained in a descriptive way rather than using an explicit mathematical formulation. In general, this approach is expected to be highly noise sensitive given the high variability of wind power production. In this section, we propose a methodology for defining and detecting a ramp in a wind power time series, based on a linear filtering approach

that aims to handle the above mentioned noise issue. As a result, we achieve a ramp characterization using a set of three parameters : the *support*, *timing* and *intensity* of the ramp.

4.2.1 Measuring time variations of wind power

The wind power production signal is characterized by high variability. For ramps, we need to propose a definition of such events that relies on a robust and computationally efficient way of measuring high and steep power variations, while appropriately handling the inherent noise in the process. Measuring variations, and detecting edges in a signal have been widely considered in the field of signal processing (for a literature overview we refer to [28]). The most common approach consists in estimating the first order derivative of the signal through filtering. The filtering considered associates the operations of smoothing and differentiating the signal. Following standard practice, we maintained a measure that would make interpretations easy and then chose to smooth the wind power signal using a moving average linear filter before computing the first order finite differences.

$$p_t^f = \frac{1}{n} \sum_{h=1}^n p_{t+h} - \frac{1}{n} \sum_{h=0}^{n-1} p_{t+h-n} \quad (4.1)$$

where p_t is a wind power time series and n is both the order of the moving average filter and the time step of finite differences. The filtered power p_t^f is merely the difference between the levels of average power from both sides of the instant t . Smoothing data allows us to regularize the differentiation operation, making it robust against noise [29]. The resulting variation measure can be rewritten by convolving the power signal p_t with the commonly known *difference of boxes* edge detector f_{DOB}

$$p_t^f = p_t * f_{DOB} \quad (4.2)$$

$$f_{DOB}(t) = \begin{cases} 0 & \text{if } t = 0 \text{ or } |t| > n \\ 1/n & \text{if } 0 < t \leq n \\ -1/n & \text{if } 0 > t \geq -n \end{cases} \quad (4.3)$$

Canny [30] introduced three criteria to evaluate edge detectors based on to their ability to detect and localize edges. Considering a model composed by an ideal step edge and white Gaussian noise, he theoretically showed the good performances of the considered edge detector f_{DOB} to detect step edges such as ramps.

In the literature on signal processing, the parameter n is generally introduced as a smoothing parameter controlling the trade off between noise reduction in the signal p_t and interference mitigation in detecting consecutive edges [31]. To avoid such interferences, n should be chosen to be no greater than the time period separating the two consecutive edges we are interested in. The choice of the value of n is described in more detail in the case-study presented in Section 4.4.1.

4.2.2 Ramp detection and characterization

Variations in the power signal p_t coincide with local extrema of the filtered power signal p_t^f (see Figure 4.1). Such extrema can be seen as a combined measure of both the magnitude and the steepness of the wind power variations. We consider that a variation is high and steep enough to be regarded as a ramp if the absolute value of p_t^f is higher than a given threshold $\tau > 0$

$$|p_t^f| \geq \tau \quad (4.4)$$

The complex geometry of a wind power variation may result in the absolute value of the filtered signal p_t^f fluctuating around the threshold τ . This phenomenon, which is responsible for breaking up edges, is known as “streaking” in literature on edge detection [30]. To palliate it, a common practice is to apply a so-called hysteresis thresholding. Rather than a single

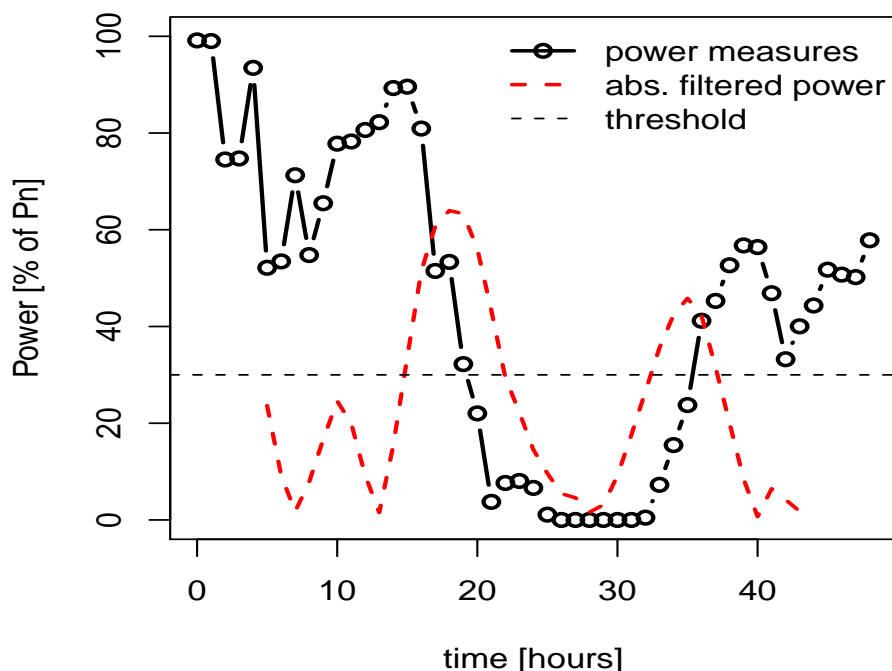


FIGURE 4.1 – Example of an hourly wind power time series p_t covering 48 hours of production from a French wind farm. The measures have been normalized based on the wind farm nominal capacity P_n . The absolute value of the filtered production p_t^f (red dashed line) upwardly crosses the threshold τ (black dashed line) twice. First, a decreasing ramp is detected. Its timing is located at $t_r = 19$ hours, its intensity represents 64,0% of the nominal capacity of the wind farm and its support is 6 hours long. It is followed by an increasing ramp at $t_r = 36$ hours, with an intensity 45.8% of P_n and a support of 4 hours.

value τ , two thresholds are then considered. Filtered outputs above the highest threshold are immediately considered as associated with an edge, as are those connected to them and lying between the two thresholds. In our study, we noticed that the streaking phenomenon occurs only rarely. For the sake of simplicity, we decided not to use this type of thresholding methodology.

A ramp is a time-limited event that can be characterized by a starting time t_s and an ending time t_e . They are defined here by the instants at which the absolute value of the filtered signal p_t^f crosses upwards and downwards the threshold τ . The period between these two instants $[t_s, t_e]$ then defines the *support* of the ramp. It is clear that the length of the support depends on the value of the threshold. In fact, ramp support should be considered as a requisite characteristic for developing our forecasting approach but is not essential to the definition of the event. Even when a ramp is not localized in time, it is useful to associate a particular timestamp to a ramp. We choose to associate to a ramp event the time t_r ($t_s \leq t_r \leq t_e$), called *timing* of the ramp, for which the absolute value of the filtered signal p_t^f reaches its maximal magnitude. If there are several maxima, the one associated to the nearest instant from the starting time t_s is chosen. This maximum defines the *intensity* of the ramp. To summarize, three quantities are defined to characterize a ramp event : support, timing and intensity.

4.3 Forecasting ramp events using ensemble wind power forecasts

The detection methodology of ramps that we introduced in the previous section relies on a filtering/thresholding approach applied to a measured wind power signal. In subsection 4.3.1, we discuss its use to detect ramps in a point forecast time series and then in an ensemble of forecast time series. In the latter case, an ensemble of ramp characteristics is produced, which may be related to different ramp events. In subsection 4.3.2, we propose solutions to cluster ramp forecasts obtained by different ensemble members into coherent groups. This enables us to discriminate between forecasts and associate them with separate events. The characteristics of the forecast events are then exploited in subsection 4.3.3 to produce probability forecasts of ramp occurrence in a set of prediction intervals.

4.3.1 Forecasting an ensemble of ramp characteristics

The methodology presented in the previous section was introduced for detecting ramps in a time series of measured wind power. Its application to a single or ensemble of wind power forecast time series is straightforward. In the case of ensembles, it is assumed that the methodology is applied to each member separately. However, it is not obvious whether the parameters, and namely the value of the threshold, used to detect ramps in a time series of measurements can be used as such to detect ramps in a time series of forecasts. Hereafter, we denote as $\hat{\tau}$ the threshold used to detect ramps in forecast time series.

Short-term wind power point forecasting models tend to overestimate production within

a low wind speed range, and underestimate it at high wind speeds. This phenomenon, which is related to the wind-to-power conversion process, was demonstrated in [32] for five power prediction models based on "statistical" and "physical" approaches (with model output statistics correction), all using spot NWP as input, and tuned to minimize the overall Root Mean Squared Error (RMSE). As a consequence, it is expected that the variations in power forecasts will on average be lower than those of the measurements. When such forecasting methods are applied to NWP ensembles, the resulting power ensembles may be poorly calibrated. In most applications, a form of recalibration is required [22, 23]. Here, in order to correctly identify ramps detected on both forecasts and observations as the same event, we can use a lower threshold value $\hat{\tau} \leq \tau$ to detect forecast ramps. One possible approach is to adjust this second threshold, so that the same amount of ramps are detected on both forecasts and observations. An alternative approach is to select the value of this threshold with respect to some other desirable properties of the considered ramp forecasting methodology. In this case, we need to keep in mind that increasing $\hat{\tau}$ decreases the number of forecast events, resulting in both less captured ramps and a reduced number of wrongly forecast events. In Section 4.4, we investigate the performance of the proposed approach to forecast ramps for different values of this threshold.

Once we have chosen a suitable value for the threshold parameter $\hat{\tau}$, the filtering/thresholding approach can be applied to each member of the ensemble of wind power forecast time series. This procedure results in the production of an ensemble of ramp forecast characteristics (timing, support, intensity). These characteristics then need to be clustered into coherent groups, each of which corresponds to a unique forecast event.

4.3.2 Clustering an ensemble of ramp characteristics

When the ramp detection procedure is applied to each member of the forecast power ensembles, it is expected that the ramps detected using each member will correspond to the same ramp event when all or part of their characteristics (intensity, support and timing) are close enough to each other. Thus, for each lead time, we propose to compute the number of ensemble members with an absolute value of filtered power higher than $\hat{\tau}$. For a given lead time, this corresponds to the number of ensemble members with overlapping ramp supports. An example of the resulting signal is given in Figure 4.2, for respectively the increasing and decreasing forecast ramps.

Based on this signal, we propose two alternative approaches for clustering the ramp characteristics. In the first approach, denoted hereafter as **A1**, we cluster forecast ramps with overlapping supports into a unique event. In the second approach, denoted as **A2**, any local maximum in the number of overlapping ramp supports defines a single event. In the example of Figure 4.2, the first approach gives two forecast events : an increasing ramp followed by a decreasing one. On the other hand, the second approach gives three forecast events : an increasing ramp and two decreasing ones. Although the second approach may result in forecasting more ramps than observed, it may allow us to capture more events. The two approaches

are evaluated in Section 4.4.

Once forecast events have been identified using one of the proposed clustering approaches, we count the number of forecasting members for each of them, taking care not to count each member more than once (e.g. a member could forecast the event two or more times because of the streaking phenomenon). We also forecast a mean timing \bar{t}_r of the event by averaging the timings forecast by the ensemble members. If we consider the mean intensity, we end up obtaining a full characterization of the forecast event from the ensemble of forecast time series.

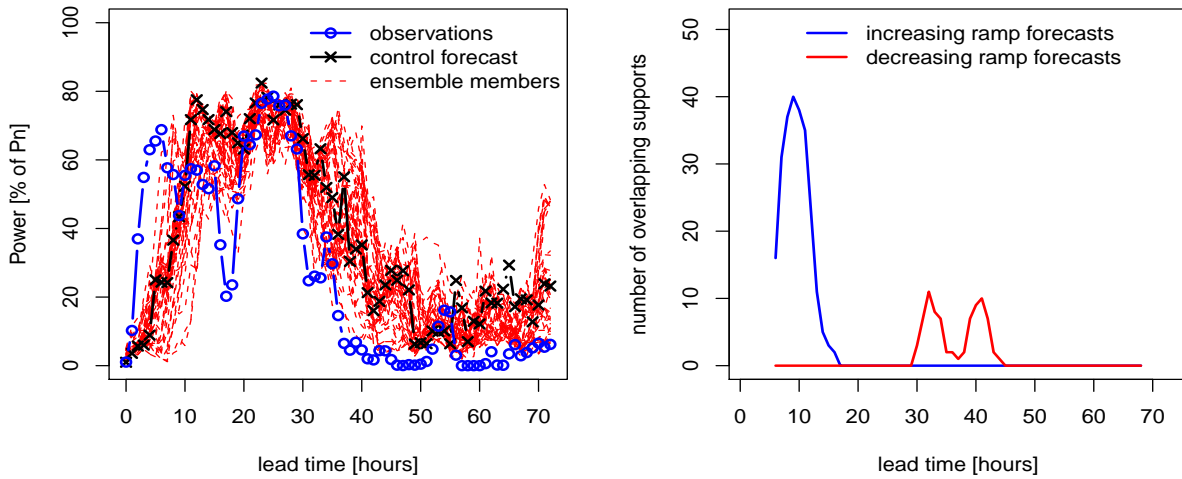


FIGURE 4.2 – Example of an ensemble of wind power production forecasts composed by the control forecast and 50 members. The figure on the left depicts the hourly time series of measured and forecast wind power up to 72 hours ahead. The right-hand figure shows the number of ensemble members with overlapping ramp supports for increasing forecast ramps (blue curve) and decreasing forecast ramps (red curve). Ramps have been detected using a time scale parameter of $n = 5$ hours and a threshold parameter $\hat{\tau} = 30\%$ of the wind farm’s nominal capacity P_n .

4.3.3 Making probabilistic forecasts of ramp occurrence using ensembles

In the proposed approach, we produce probabilistic forecasts of ramp occurrence using a set of prediction intervals $\{I_\delta, \delta = 1, \dots, \delta_{max}\}$ centered on the average forecast timing \bar{t}_r , with associated probabilities p_δ . The intervals’ radius δ are fixed beforehand and the probabilities of observing a ramp in these intervals are estimated. The maximum interval radius considered δ_{max} is a parameter of the procedure which can be configured as a function of the end-user requirements. Unlike the proposal made in [19], characterizing the phase error distribution using a set of prediction intervals with associated probabilities allows us to account for the non-occurrence of a ramp.

Estimation de l'incertitude temporelle dans la pr ediction des variations brusques et importantes de la production  olienne

To provide forecast information depending on forecast conditions, we propose to estimate p_δ conditioned to the number of ensemble members N_{mem} forecasting the ramp. For the sake of simplicity, and to produce parsimonious base-line models, we consider N_{mem} to be the only predictor. However, as a perspective of this work, one could imagine more complex models with additional inputs (e.g. average intensity forecast made by the ensemble members).

For a given interval's width 2δ , and since the center of the intervals is already forecast, it is possible to reformulate the problem of estimating p_δ in terms of a statistical regression problem. Consider the binary random variable Y_δ that equals 1 if a ramp occurs in I_δ and 0 otherwise. Thus, the probability $p_{\delta,m}$ of observing a ramp in I_δ given that m ensemble members are forecasting the ramp is given by the following regression formula

$$\begin{aligned} p_{\delta,m} &= \mathbb{P}(Y_\delta = 1 \mid N_{mem} = m) \\ &= \mathbb{E}[Y_\delta \mid N_{mem} = m] \end{aligned} \tag{4.5}$$

The estimation procedure Estimating $p_{\delta,m}$ as given by Equation (4.5) is a particular instance of a regression problem. As a consequence, there are numerous alternative estimation procedures that could be used here. In our case however, there are some particular properties that should be taken into account :

- $p_{\delta,m}$ is a probability and there are regression models dedicated to this kind of estimation problem.
- The distribution of the random variable N_{mem} used as an explanatory variable is strongly right-skewed. In other words, a ramp is more likely to be forecast by a small rather than a large number of ensemble members.

Based on these considerations, we choose to apply two alternative statistical estimation procedures, which are evaluated in Section 4.4.3. First, a Nadarya-Watson estimator is used with a varying bandwidth to introduce flexibility into our estimations and to adapt to the particular sampling of the explanatory variable N_{mem} . Then, we consider the alternative of a logistic regression model specifically dedicated to estimating probabilities.

Nadaraya-Watson estimator A Nadarya-Watson estimator makes estimations according to the following generic formula

$$p_{\delta,m} = \frac{\sum_{i=1}^n \mathcal{K}_\lambda(m_i, m) Y_\delta^i}{\sum_{i=1}^n \mathcal{K}_\lambda(m_i, m)} \tag{4.6}$$

where n is the size of the data set dedicated to probability estimations and \mathcal{K}_λ is a kernel function. Regression techniques using kernels fit a local model around each target point m . The value $\mathcal{K}_\lambda(m_i, m)$ gives the weighting of points m_i in the neighborhood of the target point m . The kernel's bandwidth λ gives the size of such a neighborhood and controls the

estimation bias-variance trade off. Increasing λ results in averaging more observations and lowers the variance (but increases the bias) in each target point estimation. These techniques are very popular as they do not require any parametric assumption. In our study, we consider a tricube kernel and select λ by making it vary with m according to a nearest-neighbors procedure

$$\lambda(m) = |m - m_{[k]}| + 1 \quad (4.7)$$

where $m_{[k]}$ is the k th closest point from the target m . The parameter k is selected from a 10-fold cross-validation procedure. A local choice of λ allows us to incorporate more information about the probability law generating data points m_i and often gives better results when estimating curves with a complex shape [33]. For an overview on kernel smoothers and bandwidth selection procedures we refer to [34, 35].

Logistic regression The logistic regression model allows us to infer ramp occurrence probabilities from a linear function of the number of ensemble members m forecasting a ramp

$$\log \frac{p_{\delta,m}}{1 - p_{\delta,m}} = \alpha_{\delta}m + \beta_{\delta} \quad (4.8)$$

where α_{δ} and β_{δ} are the model parameters to estimate. To ensure that the estimated probabilities remain within $[0, 1]$, the modeling requires us to express such probabilities as a linear function of m through a logit transformation. The model is fit by maximum likelihood, assuming the conditional distribution of Y_{δ} given N_{mem} is binomial. For all values of δ , a statistical test (the Wald test) rejects the hypothesis that assumes a null value of coefficients α_{δ} and β_{δ} with a significance level of 5%. For an introduction to logistic and generalized linear models, we refer to [34, 36].

4.4 Evaluation framework and results

4.4.1 The Case-Study

In order to evaluate the proposed methodology, we considered a wind farm with a nominal capacity of 8MW, located on a complex terrain in the south of France (a few dozen kilometers from the Mediterranean Sea). Power measurements delivered by the SCADA system of the wind farm were considered. They covered a period of 18 months from July 2004 to December 2005 with a 10-min temporal resolution. For the purpose of the study, the data was averaged to hourly values.

In our study, ramp events correspond to variations detected with a filter (half) width of $n = 5$ hours. Such a value is reasonable if variations under study are related to somewhat persistent changes in weather conditions. Appropriate choices could be made by end-users

Estimation de l'incertitude temporelle dans la prédiction des variations brusques et importantes de la production éolienne

focusing on shutdown events, for instance². In this case, a lower value of n would be required. Further work could include a multi-scale analysis of the wind power signal using multi-scale edge detection techniques [28]. For a variation to be considered as a ramp, its minimum intensity τ has to be set according to which proportion of the most “extreme” (e.g. highest and steepest) variations we are interested in. We consider a value of $\tau = 30\%$ of the nominal capacity P_n of the considered wind farm. With such a value, we detected 168 ramps during the period between 1st April 2005 and 31st December 2005, that is an average 4.2 ramps a week. Note that our methodology is independent of the value of τ and a more specific choice could be made by end-users. As mentioned in Section 4.3.1, we will now investigate the performance of our approach to forecasting ramps considering different threshold values $\hat{\tau}$ to detect ramps on wind power forecast ensembles.

NWP ensembles of 51 members are provided by the EPS system of ECMWF with a spatial resolution of 1° in both longitude and latitude. This resolution corresponds to about 75 – 80 km in the East-West direction and 110 km in the North-South direction. The NWP data is issued twice a day with a temporal resolution of 6 hours and for a horizon of 72 hours. Hourly predictions were obtained through interpolating the 6-hour values. To forecast wind power, we considered weather forecasts generated at the closest grid point to the wind farm located 10 meters above ground level. We used the *Random Forest* nonparametric estimation procedure to produce wind power forecasts using wind speed and direction NWPs as input. *Random Forest* is a machine-learning algorithm that aggregates predictions from a large number of regression trees, each tree being built from a bootstrap replica of the sample data and random selection of potential predictors. Recent work on meteorological downscaling and post-processing acknowledges the robustness of *Random Forest* against over-fitting and its ability to deal with nonlinearity and complex interactions between variables [37, 38]. For more details we refer to [34, 39]. To deal with ensembles, we applied the Random Forest procedure to each member of the NWP ensemble to obtain a corresponding power forecast ensemble.

Our wind power forecasting model was trained over a nine-month period (July 2004 - March 2005) and tested for another nine months (April to December 2005). In the testing set, the model provides a root mean squared error and a mean absolute error not greater than respectively 15% and 11% of the nominal capacity of the wind farm for the next 24h. This is a satisfactory performance given the state of the art [40], especially if one considers the complexity of the terrain in which the wind farm is embedded and the rather coarse resolution of the NWP data. The data sets used for training and testing the ramp forecasting models were four and a half months long each, covering the 9-month period between April and December 2005. We derive and hereafter evaluate ramp forecasts taking prediction intervals with a maximal radius value of $\delta_{\max} = 8$ hours. With such a value, we expect to describe most of the phase error distribution from the considered set of prediction intervals.

2. In situations with very high wind speeds, some or all of a wind farm’s turbines can be temporary stopped to avoid damage due to strong mechanical constraints. Such situations can turn into high variations of decreasing and increasing wind power production within a short period of time

4.4.2 Evaluating the capture of ramp events from ensemble-based forecasts

In this section we focus on evaluating the rate of observed ramps that are effectively forecast, denoted as *ramp capture* ratio [19].

Figure 4.3 gives this ratio for ensemble-based forecasts and forecasts derived from the control member. As noticed in Section 4.3.1, predicting ramps from forecast variations of lower intensity (e.g. by decreasing $\hat{\tau}$), results in capturing more events. This property is valid when predicting ramps from a single wind power scenario, but may not hold when considering ensembles. Actually, it depends on the approach used to cluster forecasts issued by different ensemble members. When using the approach **A1**, low values of $\hat{\tau}$ result in ramp supports forecast by the ensemble to overlap, and ultimately in separated forecast events to be merged. This is the reason why in Figure 4.3, for $\hat{\tau} \leq 20\%$ of P_n and with clustering approach **A1**, the ramp capture decreases with $\hat{\tau}$.

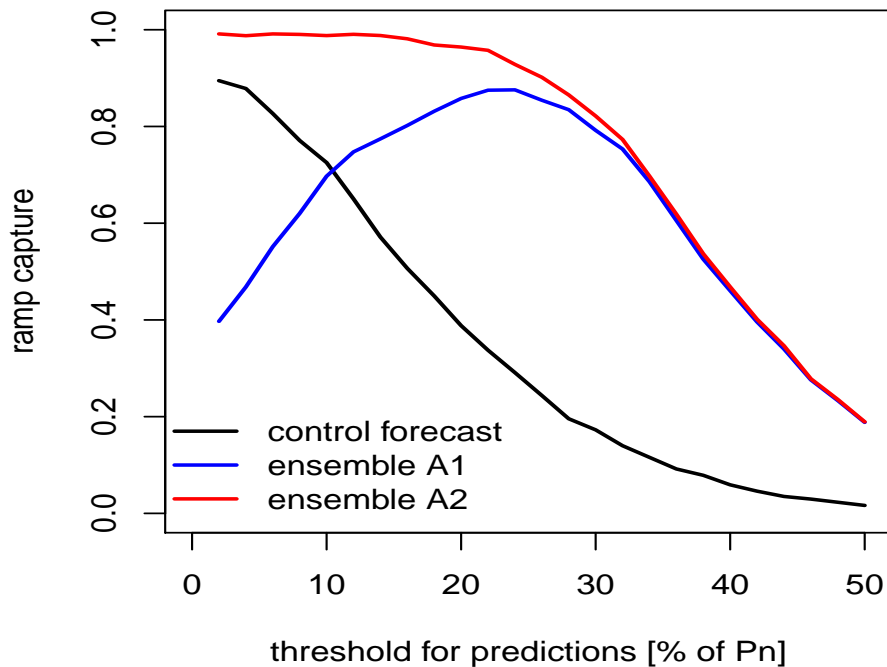


FIGURE 4.3 – Ramp capture results when forecasting ramps using the control forecast (black curve) or the ensembles (blue curve is for clustering approach **A1**, red curve for approach **A2**). Results are for values of $\hat{\tau}$ ranging from 2% to 50% of the wind farm nominal capacity P_n , and a maximum delay between forecast and observed ramp events of $\delta_{\max} = 8$ hours.

As seen in Figure 4.3, ensembles generally outperform the control member in terms of ramp capture. However, such improvements may coincide with a higher number of false

alarms, e.g. events that are forecast but not observed. In fact, the use of ensembles may not result in a better ramp capture/forecast accuracy trade off. Alternative approaches to cluster ramp forecasts issued by different ensemble members could be envisaged. We have considered other clustering approaches, such as hierarchical agglomerative clustering with an euclidean distance [34]. However, such clustering approaches turn out to be far more computationally demanding when the number of ramp forecasts to cluster is increased (e.g. when decreasing $\hat{\tau}$).

4.4.3 Evaluating ensemble-based probability forecasts of ramp occurrence

Here we evaluate the probability forecasts for ramp occurrence. We first propose using the Brier score (BS) [41], which is a dedicated measure of accuracy. Consider $p_i = p_{\delta,m}^i$ as a probability forecast of ramp occurrence in a prediction interval I_δ . Let $y_i = y_\delta^i$ be equal to one if a ramp is observed in I_δ and zero otherwise, then

$$\text{BS} = \frac{1}{n} \sum_{i=1}^n (p_i - y_i)^2 \quad (4.9)$$

where n is the test set sample size. As a reference approach, we consider the climatology which, for a given interval's width 2δ , derives unconditional probability forecasts from the empirical event frequency $\bar{y} = 1/n \sum_{i=1}^n y_i$. The relative improvement in terms of the decrease in forecasting errors, referred to as Brier skill score with respect to climatology (BSS_{clim}), is given in Table 4.1. Conditioning clearly improves forecast accuracy. Such improvement is paramount for low values of $\hat{\tau}$, e.g. for high ramp capture. When focusing on the approach **A1**, such improvement also increases with the size of prediction intervals I_δ , which then results in better performances compared to the approach **A2** for large values of δ (e.g. $\delta = 8$ hours in Table 4.1). However, the sampling uncertainty in the estimation of BSS_{clim} makes any further discrimination between approaches **A1** and **A2** difficult. For the same reason, it is not easy to conclude in favor of a particular estimation procedure between the logistic regression model and the Nadarya-Watson estimator.

In addition to using the Brier score, we evaluated our forecasts according to a reliability/sharpness paradigm [43, 44]. Results for a particular threshold value $\hat{\tau} = 30\%$ of the wind farm nominal capacity, using the clustering approach **A2** and the logistic regression model, are shown in Figure 4.4. Forecasts show reliability (top left Figure), which does not deviate from perfect reliability (first diagonal) any more than the sampling uncertainty does. The latter was estimated with 90% confidence intervals (vertical segments) derived from the resampling technique proposed by Broecker and Smith [45]. An alternative was to derive them analytically considering the Poisson-Binomial distribution of $n\bar{y}$ [46]. The results from the two approaches were found to be very close.

The top right and bottom plots of Figure 4.4 show the sharpness property of our forecasts. We can see that the probability of a ramp occurring in prediction intervals increases with the

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

TABLE 4.1 – Brier skill score with respect to climatology BSS_{clim} (in percentages) of ensemble-based probability forecasts of ramp occurrence in prediction intervals I_δ (δ is in hours). Results are given for both the clustering approaches **A1** and **A2**, and for the logistic regression (log. reg.) and the Nadarya-Watson (N.W.) estimation procedures. To account for sampling uncertainty, the standard deviation of BSS_{clim} (given in parenthesis) has been estimated following the theoretical work of Bradley et al. [42].

$\hat{\tau}$ (% P_n)	log. reg.			N.W.		
	$\delta = 2$	$\delta = 5$	$\delta = 8$	$\delta = 2$	$\delta = 5$	$\delta = 8$
Clustering approach A1						
10	5.5 (1.2)	11.1 (1.7)	16.6 (2.2)	5.4 (1.1)	10.8 (1.5)	16.6 (2.1)
20	3.8 (1.2)	9.9 (1.7)	14.3 (2.1)	4.5 (1.0)	9.8 (1.4)	13.8 (1.8)
30	3.7 (1.2)	8.0 (1.7)	9.5 (1.9)	4.2 (1.1)	8.2 (1.5)	9.4 (1.7)
40	2.9 (1.3)	1.5 (2.6)	3.3 (2.4)	2.8 (1.1)	3.7 (2.5)	4.8 (2.3)
Clustering approach A2						
10	6.0 (1.0)	10.2 (1.3)	9.2 (1.3)	6.2 (0.9)	10.9 (1.3)	9.9 (1.3)
20	5.8 (1.1)	9.9 (1.4)	8.9 (1.4)	6.1 (1.0)	9.7 (1.3)	8.6 (1.4)
30	3.9 (1.2)	6.9 (1.3)	6.3 (1.4)	3.9 (1.2)	7.0 (1.4)	5.9 (1.5)
40	3.2 (1.21)	1.0 (1.8)	1.2 (1.7)	3.2 (1.3)	2.8 (2.0)	0.9 (2.1)

number of members forecasting it. At the same time, ramps are seldom forecast with high probability. We quantified reliability and sharpness using measures derived from the decomposition of the Brier score proposed by Murphy [47]. Results showed that the decreasing skill of our forecasts (see Table 4.1) while $\hat{\tau}$ increases was due to the simultaneous decrease in reliability and sharpness. In any case, high values of $\hat{\tau}$ (e.g. $\hat{\tau} > 40\%$ of P_n) make it possible to mitigate false alarms, which may be desirable when making deterministic forecasts of ramps. Following our probabilistic approach, the choice should be for lower threshold values leading to (sometimes large numbers of) forecasts with good reliability and sharpness.

To illustrate the forecast product of the proposed methodology, the 3 days ahead forecast scenario given in Figure 4.2 is represented in Figure 4.5, with prediction intervals and associated probability forecasts of ramp occurrence. Forecasts were derived from the clustering approach **A2** and the logistic regression model. As we described in Section 4.3.2, the situation considered should present two decreasing ramp forecasts. For more visibility, however, we removed one of them.

Estimation de l'incertitude temporelle dans la prédiction des variations brusques et importantes de la production éolienne

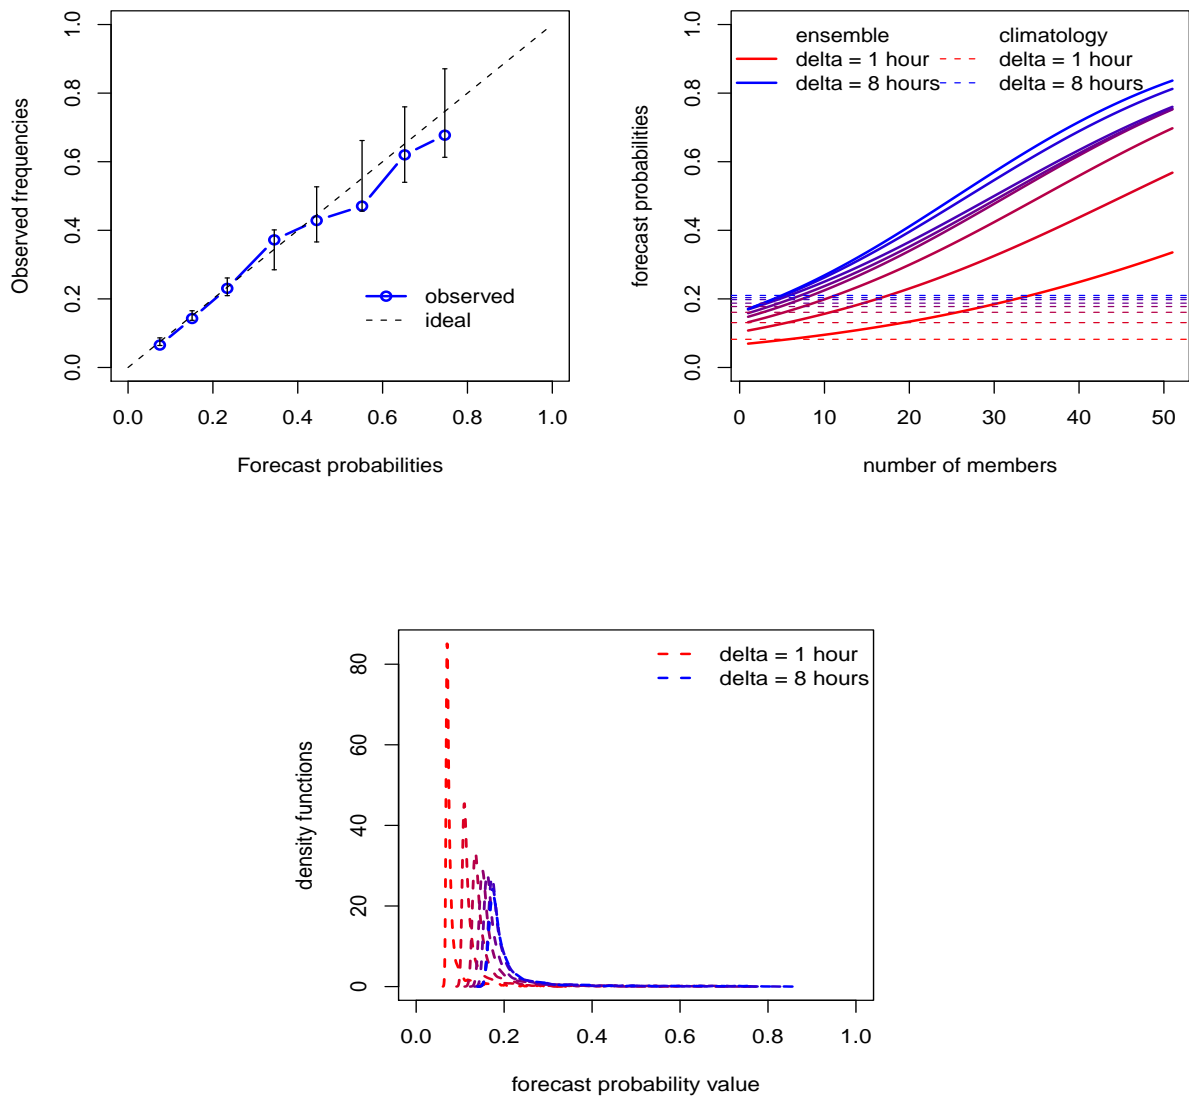


FIGURE 4.4 – Reliability (top left Figure) and sharpness (top right and bottom Figures) of ensemble-based probability forecasts of ramp occurrence in prediction intervals I_δ . Results are for forecasts derived from the clustering approach **A2**, with $\hat{\tau} = 30\%$ of P_n and the logistic regression model. To take the sampling uncertainty into account when estimating the event frequencies (top left Figure), 90% centered confidence intervals were derived using the resampling technique proposed in [45].

4.5 Conclusions and Perspectives

There is growing demand for developing wind power forecasting models focusing on certain extreme situations. One well-known situation is the so-called ramp event, which involves

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

sharp and high variations in production experienced by wind farms in the space of a few hours. These variations are critical for managing power systems with high wind penetration, as they can imply complex changes in power supply. For a power system operator, an estimation of the uncertainty of a forecast ramp should provide valuable information for making management decisions.

The first challenge in ramp forecasting is to correctly define a ramp. We proposed a definition based on filtering, guided by the significant signal processing literature on edge detection. Such a definition addresses several issues inherent to defining a ramp : at what level of power and within what duration does a variation represent a "ramp" for the end-user? We discussed these questions and proposed a detection methodology using two parameters that make it possible to set at what time scale and magnitude a variation is considered to be a ramp. Such parameters can be set depending on either the modeler's or the end-user's opinion.

A single time series of wind power forecasts up to several days may not include enough information to make secure management decisions related to the potential occurrence of a ramp. In this paper, we studied the extent to which numerical weather prediction ensembles could provide information when forecasting ramps with associated uncertainty. We showed that ensembles used with our methodology can better capture ramp events than when considering a unique wind power scenario.

Then, we set out to estimate the uncertainty associated with ramp forecasts using a set of prediction intervals with associated probabilities of ramp occurrence. We introduced sharpness into our forecasts by conditioning them to the number of ensemble members forecasting a ramp. The resulting forecasts turned out to be reliable with greater accuracy regarding climatology. Our conclusions relate to data from a multi-megawatt wind farm located on a complex terrain in the south of France, and numerical weather prediction ensembles of 51 members from the EPS system of ECMWF. In further work, an evaluation of the methodology on more sites should help to validate our conclusions under different weather regimes.

An interesting perspective would be to compare the forecasting ramp performance of different wind power forecast ensembles. Indeed, the methodology we developed in this paper could be used to forecast ramps from either the commonly known *poor man's* ensembles, or from ensembles derived from multivariate statistical sampling, such as those proposed in [48]. The latter could provide a good alternative to numerical weather prediction ensembles for forecasting ramps, as their generation can be far less computationally expensive. Particular attention should also be paid to future potential applications of the proposed approach in forecasting wind generation ramps from a portfolio of wind farms. Finally, we observed that different ramp typologies occur, and the limits of a single ramp definition will need to be explored in further work.

Estimation de l'incertitude temporelle dans la prédiction des variations brusques et importantes de la production éolienne

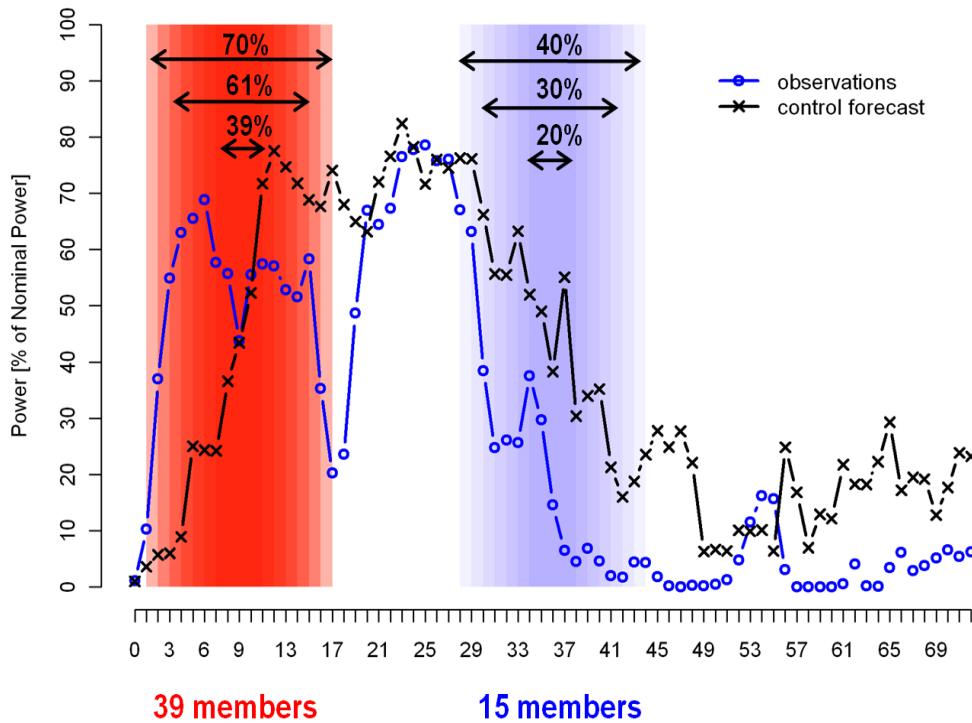


FIGURE 4.5 – Prediction intervals I_δ , $\delta = 1, \dots, 8$ hours for an increasing ramp forecast by 39 members, followed by a decreasing one forecast by 15 members. Probability forecasts of ramp occurrence (given in percentages at the top of the figure) were derived using the clustering approach A2, $\hat{\tau} = 30\%$ of P_n and the logistic regression model. The change in forecast probability depending on the number of members forecasting a ramp provides a good illustration of the sharpness property of the proposed methodology.

Troisième partie : Résultats complémentaires

Dans cette partie, nous discutons plus en détails des résultats liés à la prédiction de l'instant d'apparition des variations brusques et importantes de la production.

Compromis "précision / capture"

Nous commençons par donner plus de détails sur le compromis entre capture et précision de prédiction des ruptures, que nous avons évoqué dans la partie précédente. La Figure 4.3 montrait comment le paramètre $\hat{\tau}$ contrôle le taux de capture des ruptures en question. Nous en avons conclu que les performances des ensembles étaient supérieures à celles du membre de contrôle. Cependant, nous avons également évoqué le fait qu'un taux de capture supérieur pouvait être accompagné d'un taux de précision inférieur à celui du membre de contrôle. Pour pleinement apprécier les performances des ensembles et celles du membre de contrôle, il convient d'observer le compromis entre taux de capture et précision de prédiction. Ce compromis est représenté Figure 4.6. A travers ce dernier, les approches de prédiction basées respectivement sur les ensembles et sur le membre de contrôle, sont évaluées comme des approches de classification $f_{\hat{\tau}}^e$ et $f_{\hat{\tau}}^c$:

$$f_{\hat{\tau}}^e(m) = \mathbb{1}_{m \geq N_{\min}}, \quad f_{\hat{\tau}}^c(\hat{I}_c) = \mathbb{1}_{|\hat{I}_c| \geq \hat{\tau}},$$

où $m = m(\hat{\tau})$ désigne le nombre de membres d'un ensemble prédisant une variation d'intensité supérieure à $\hat{\tau}$ (en valeur absolue), et \hat{I}_c désigne l'intensité d'une variation prédite par le membre de contrôle. Le paramètre N_{\min} permet de définir différents classifieurs, en exploitant la propriété de résolution (i.e. "sharpness") des ensembles :

$$f_{\hat{\tau}}^e(m) = \mathbb{1}_{p_{\delta, m} \geq p_{\delta, N_{\min}}},$$

pourvu que $p_{\delta, m}$ défini Equation (4.5) soit bien monotone en m . Le compromis représenté Figure 4.6 vient alors de la décomposition de l'erreur moyenne de classification que nous avons décrite Equation (3.7), Section 3.2.3. L'évaluation de notre approche considérée comme une approche de classification montre finalement la difficulté de dépasser avec les ensembles, les performances du membre de contrôle. Ces dernières constituent une sorte de "borne supérieure" que l'on parvient néanmoins à atteindre en jouant sur la valeur du paramètre N_{\min} (voir aussi les résultats obtenus sur d'autres fermes en Annexe A).

Précision des prédictions ponctuelles de l'instant d'apparition d'une rupture

Nous nous intéressons maintenant à la précision des prédictions ponctuelles de l'instant d'apparition d'une variation brusque et importante de la production. Dans la Figure 4.7 sont montrés : la racine carré de l'erreur quadratique moyenne (RMSE, graphe du haut), le biais

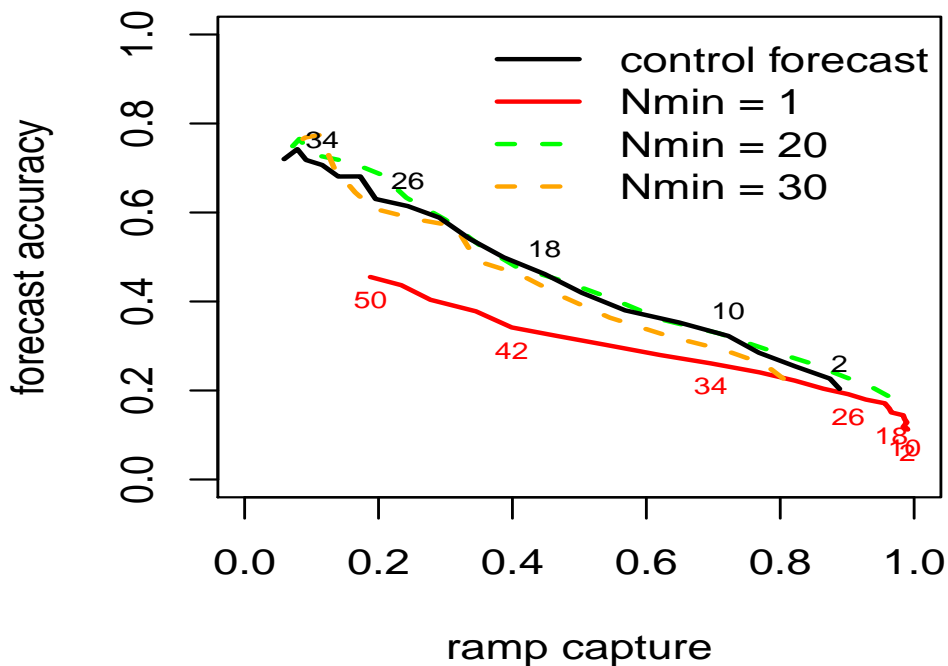


FIGURE 4.6 – Compromis "précision / capture" – Courbes paramétrées par $\hat{\tau}$ (dont certaines valeurs ont été représentées ici par des chiffres), représentant la précision de prédiction des variations brusques et importantes de la production par le membre de contrôle et les ensembles, en fonction du taux de capture. Une valeur adéquate du paramètre N_{min} , permet d'atteindre avec les ensembles des performances similaires à celles obtenues par le membre de contrôle (voir le texte pour plus de détails). Les résultats montrés ici ont été obtenus pour des ruptures d'intensité minimale $\tau = 30\% P_n$, prédites à partir de l'approche d'agrégation A2, et pour un rayon d'intervalle $\delta = 8 h$.

(graphe en bas à gauche), et l'écart-type (en bas à droite) des erreurs de prédiction. De manière générale, on observe un biais dans les prédictions aussi bien pour les ensembles, que pour le membre de contrôle. Le modèle EPS semble ainsi prédire en avance les phénomènes responsables des ruptures observées dans la production de chacune des fermes de notre étude (voir aussi Annexe A). En choisissant une valeur adéquate de $\hat{\tau}$ (i.e. proche de celle de τ), on parvient néanmoins à faire disparaître ce biais. De manière générale, les prédictions réalisées à partir du membre de contrôle sont plus précises que ne le sont celles réalisées à partir des ensembles. Davantage biaisées, ces dernières sont généralement aussi plus variables. En ce sens, les résultats obtenus pour les autres fermes de notre cas d'étude (cf Annexe A) sont plus représentatifs que ceux présentés Figure 4.7. Cette variabilité peut s'expliquer par le nombre généralement restreint de membres à partir duquel différentes prédictions sont agrégées.

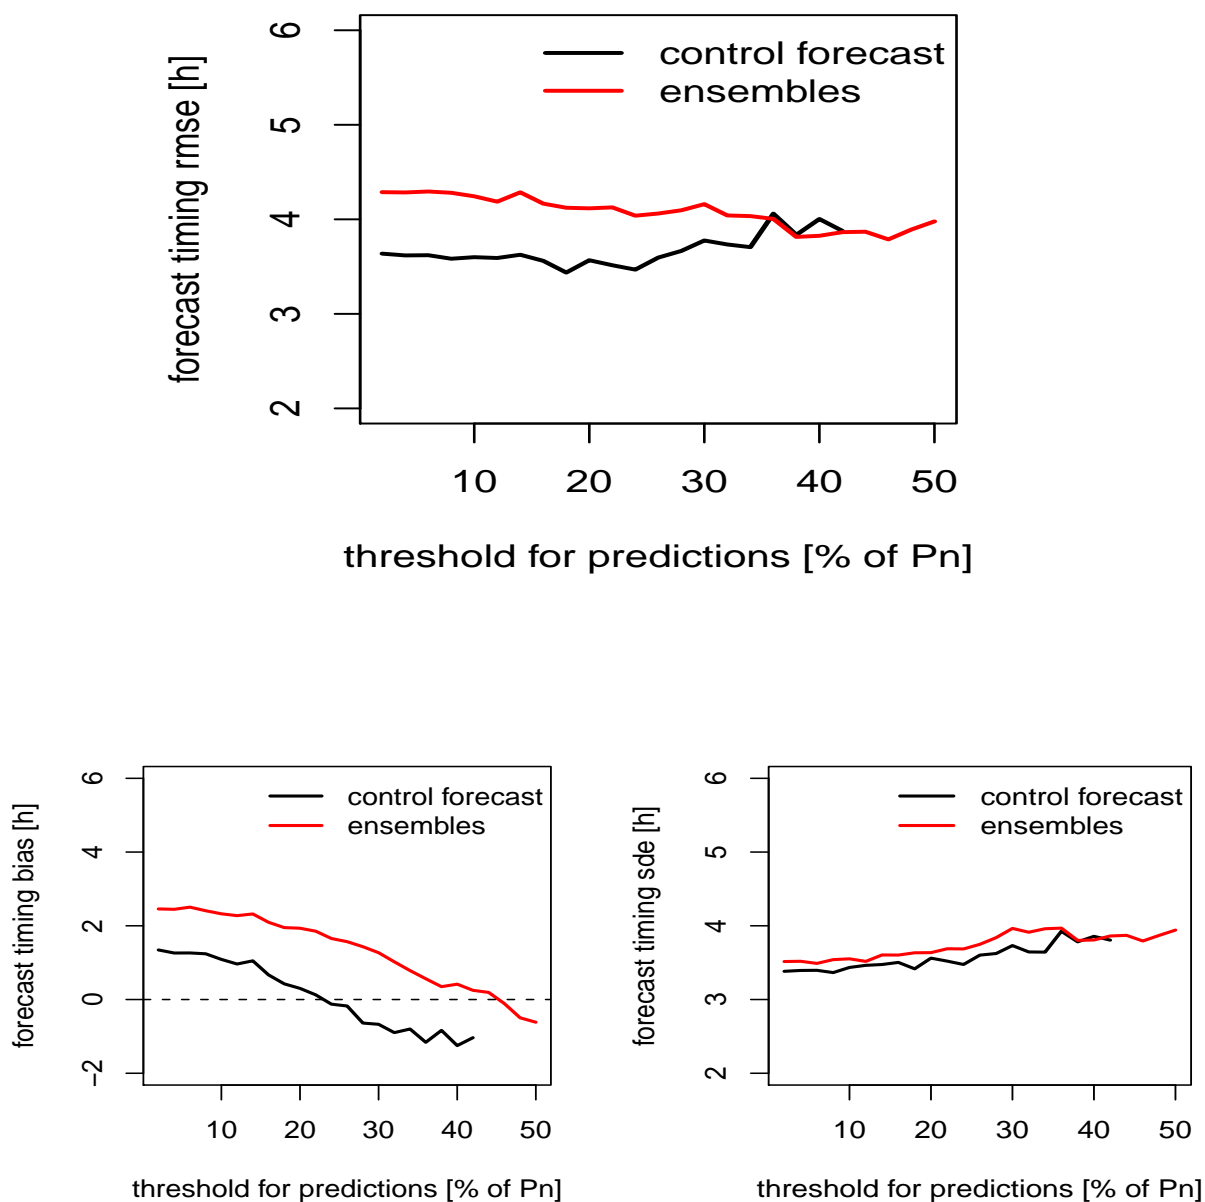


FIGURE 4.7 – Précision des prédictions ponctuelles de l’instant d’apparition d’une rupture – Racine carré de l’erreur quadratique moyenne (graphe du haut), biais (graphe en bas à gauche), et écart-type (graphe en bas à droite) des erreurs associées aux prédictions ponctuelles de l’instant d’apparition d’une rupture dans un signal de production. Les prédictions réalisées à partir des ensembles (courbes rouges) sont moins précises que celles réalisées à partir du membre de contrôle (courbes noires), du fait d’un biais et d’une variabilité plus importante. Les résultats montrés ici ont été obtenus pour des ruptures d’intensité minimale $\tau = 30\% P_n$, à partir de l’approche d’agrégation **A2**, et pour un rayon d’intervalle $\delta = 8 h$.

Bibliographie

- [1] R. Doherty and M. O'Malley. A new approach to quantify reserve demand in systems with significant installed wind capacity. *Power Systems, IEEE Transactions on*, 20(2) :587 – 595, 2005.
- [2] E.D. Castronuovo and J.A.P. Lopes. On the optimization of the daily operation of a wind-hydro power plant. *Power Systems, IEEE Transactions on*, 19(3) :1599 – 1606, 2004.
- [3] J.M. Angarita and J.G. Usaola. Combining hydro-generation and wind energy : Biddings and operation on electricity spot markets. *Electric Power Systems Research*, 77(5-6) :393 – 400, 2007.
- [4] P. Pinson, C. Chevallier, and G. Kariniotakis. Trading wind generation from short-term probabilistic forecasts of wind power. *Power Systems, IEEE Transactions on*, 22(3) :1148 –1156, 2007.
- [5] B.J. Bremnes. A comparison of a few statistical models for making quantile wind power forecasts. *Wind Energy*, 9(1) :3–11, 2006.
- [6] J.K. Moller, H.Aa. Nielsen, and H. Madsen. Time-adaptive quantile regression. *Computational Statistics & Data Analysis*, 52(3) :1292 – 1303, 2008.
- [7] H.Aa. Nielsen, H. Madsen, and T.S. Nielsen. Using quantile regression to extend an existing wind power forecasting system with probabilistic forecasts. *Wind Energy*, 9(1-2) :95–108, 2006.
- [8] J. Juban, N. Siebert, and G. Kariniotakis. Probabilistic short-term wind power forecasting for the optimal management of wind generation. In *Proceedings of the IEEE Power Tech Conference, Lausanne, Switzerland*, 2007.
- [9] J.W. Taylor, P.E. McSharry, and R. Buizza. Wind power density forecasting using ensemble predictions and time series models. *Energy Conversion, IEEE Transactions on*, 24(3) :775 –782, 2009.
- [10] A. Costa, A. Crespo, J. Navarro, G. Lizcano, H. Madsen, and E. Feitosa. A review on the young history of the wind power short-term prediction. *Renewable and Sustainable Energy Reviews*, 12(6) :1725 – 1744, 2008.
- [11] G. Giebel, G. Kariniotakis, and R. Brownsword. The state of the art on short-term wind power prediction - A literature overview. Technical report, ANEMOS EU project, deliverable report D1.1. [Available online : <http://www.anemos-project.eu>], 2003.
- [12] P. Pinson. Catalogue of complex to extreme situations. Technical report, EU Project SafeWind, Deliverable Dc1.2. [Available online : <http://www.safewind.eu>], 2009.
- [13] N.J. Cutler, M. Kay, K. Jacka, and T.S. Nielsen. Detecting, categorizing and forecasting large ramps in wind farm power output using meteorological observations and WPPT. *Wind Energy*, 10(5) :453–470, 2007.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

- [14] N.J. Cutler. *Characterizing the uncertainty in potential large rapid changes in wind power generation*. PhD thesis, Electrical Engineering & Telecommunications, Faculty of Engineering, UNSW. [Available online : <http://handle.unsw.edu.au/1959.4/43570>], 2009.
- [15] H. Zheng and A. Kusiak. Prediction of wind farm power ramp rates : A data-mining approach. *Journal of solar energy engineering*, 131 :031011.1–031011.8, 2009.
- [16] H. Zareipour. Wind power ramp events classification and forecasting : A data mining approach. In *Proceedings of the 2011 IEEE Power and Energy Society (PES) Annual General Meeting, Detroit, USA*, 2011.
- [17] C. Kamath. Associating weather conditions with ramp events in wind power generation. In *IEEE PES Power Systems Conference & Exposition, Phoenix, Arizona*, 2011.
- [18] N.J. Cutler, H.R. Outhred, I.F. MacGill, M.J. Kay, and J.D. Kepert. Characterizing future large, rapid changes in aggregated wind power using Numerical Weather Prediction spatial fields. *Wind Energy*, 12(6) :542–555, 2009.
- [19] B. Greaves, J. Collins, J. Parkes, and A. Tindal. Temporal forecast uncertainty for ramp events. *Wind Engineering*, 33(11) :309–319, 2009.
- [20] C. Ferreira, J. Gama, L. Matias, A. Botterud, and J. Wang. A survey on wind power ramp forecasting. A report from the Argonne U.S. Department of Energy Laboratory. [Available online at <http://www.dis.anl.gov/>], 2010.
- [21] P. Pinson and G. Kariniotakis. Conditional prediction intervals of wind power generation. *Power Systems, IEEE Transactions on*, 25(4) :1845–1856, 2010.
- [22] H.Aa. Nielsen, T.S. Nielsen, H. Madsen, J. Badger, G. Giebel, L. Landberg, K. Sattler, L. Voulund, and J. Tøfting. From wind ensembles to probabilistic information about future wind power production - Results from an actual application. In *Proceedings of the IEEE PMAPS 2006 Conference, Probabilistic Methods Applied to Power Systems, Stockholm, Sweden*, 2006.
- [23] P. Pinson and H. Madsen. Ensemble-based probabilistic forecasting at Horns Rev. *Wind Energy*, 12(2) :137–155, 2009.
- [24] P.A. Chessa and F. Lalaurette. Verification of the ECMWF ensemble prediction system forecasts : A study of large-scale patterns. *Weather and Forecasting*, 16(5) :611–619, 2001.
- [25] WEPROG ApS. High resolution ensemble for Horns Rev - HRensembleHR -. Technical report, Project funded by the Danish PSO F&U Program, Final Report. [Available online : <http://www.hrensemble.net>], 2010.
- [26] E. Gritmit and C. Potter. A prototype day-ahead forecast system for rapid wind ramp events. In *Proceedings of Windpower 2008 Conference and Exhibition, Houston, Texas*, 2008.
- [27] P. Pinson and R. Girard. Evaluating the quality of scenarios of short-term wind power generation. *Applied Energy*, 96(0) :12 – 20, 2012.
- [28] D. Ziou and S. Tabbone. Edge detection techniques - An overview. *International Journal of Pattern Recognition and Image Analysis*, 8 :537–559, 1998.

Estimation de l'incertitude temporelle dans la prédiction des variations brusques et importantes de la production éolienne

- [29] V. Torre and T.A. Poggio. On edge detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-8(2) :147–163, 1986.
- [30] J. Canny. A computational approach to edge detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-8(6) :679–698, 1986.
- [31] D. Demigny. On optimal linear filtering for edge detection. *Image Processing, IEEE Transactions on*, 11(7) :728–737, 2002.
- [32] P. Pinson. *Estimation of the uncertainty in wind power forecasting*. PhD thesis, MINES ParisTech. [Available online : <http://pastel.paristech.org>], 2006.
- [33] J. Fan and I. Gijbels. Variable bandwidth and local linear regression smoothers. *Annals of Statistics*, 20 :2008–2036, 1992.
- [34] T. Hastie, R. Tibshirani, and J. Friedman. *The elements of statistical learning, second edition : Data mining, inference, and prediction*. Springer Series in Statistics. Springer, 2nd ed. 2009. corr. 3rd printing edition, 2009.
- [35] W. Schucany. Kernel smoothers : An overview of curve estimators for the first graduate course in nonparametric statistics. *Statistical Sciences*, 19 :663–675, 2004.
- [36] H. Madsen and P. Thyregod. *An introduction to general and generalized linear models*. Chapman & Hall, 2010.
- [37] E. Eccel, L. Ghielmi, P. Granitto, R. Barbiero, F. Grazzini, and D. Cesari. Prediction of minimum temperatures in an alpine region by linear and non-linear post-processing of meteorological models. *Nonlinear Processes in Geophysics*, 14(3) :211–222, 2007.
- [38] R. Davy, M. Woods, C. Russell, and P. Coppin. Statistical downscaling of wind variability from meteorological fields. *Boundary-Layer Meteorology*, 135 :161–175, 2010.
- [39] L. Breiman. Random Forests. *Machine Learning*, 45 :5–32, 2001.
- [40] G. Kariniotakis, I. Marti, D. Casas, P. Pinson, T.S. Nielsen, H. Madsen, G. Giebel, J. Usaola, I. Sanchez, A.M. Palomares, R. Brownsword, J. Tambke, U. Focken, M. Lange, P. Loucka, G. Kallos, C. Lac, G. Sideratos, and G. Descombes. What performances can be expected by short-term wind power prediction models depending on site characteristics? In *Proceedings of the 2004 European Wind Energy Conference EWEC'04, London, UK*, 2004.
- [41] G. Brier. Verification of forecast expressed in terms of probability. *Monthly weather review*, 78 :1–3, 1950.
- [42] A. Bradley, S.S. Schwartz, and T. Hashino. Sampling uncertainty and confidence intervals for the Brier score and Brier skill score. *Weather and Forecasting*, 23(5) :992–1006, 2008.
- [43] T. Gneiting, F. Balabdaoui, and A.E. Raftery. Probabilistic forecasts, calibration and sharpness. *Journal of the Royal Statistical Society : Series B (Statistical Methodology)*, 69(2) :243–268, 2007.
- [44] P. Pinson, H.Aa. Nielsen, J.K. Moller, H. Madsen, and G. Kariniotakis. Non-parametric probabilistic forecasts of wind power : required properties and evaluation. *Wind Energy*, 10(6) :497–516, 2007.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

- [45] J. Broecker and L.A. Smith. Increasing the reliability of reliability diagrams. *Weather and Forecasting*, 22(3) :651–661, 2007.
- [46] Y. Hong. On computing the distribution function for the Poisson binomial distribution. *Computational Statistics & Data Analysis*, 59(0) :41 – 51, 2013.
- [47] A.H. Murphy. A new vector partition of the probability score. *Journal of Applied Meteorology*, 12 :595–600, 1973.
- [48] P. Pinson, H. Madsen, H.Aa. Nielsen, G. Papaefthymiou, and B. Klöckl. From probabilistic forecasts to statistical scenarios of short-term wind power production. *Wind Energy*, 12(1) :51–62, 2009.

Chapitre 5

Conclusions générales

5.1 Retour sur les contributions et conclusions

La prédiction à court terme de la production éolienne est reconnue comme étant un des moyens permettant de faciliter l'intégration à grande échelle de l'éolien dans les mix énergétiques. Les efforts fournis en recherche et développement lors des vingt-cinq dernières années ont permis à de nombreuses approches de voir le jour. Leurs performances dans un contexte opérationnel, sont reconnues comme étant généralement satisfaisantes. Toutefois, face à certaines situations qualifiées d'"extrêmes", les approches classiques ne donnent pas entière satisfaction. Les performances de ces dernières s'en trouvent réduites. Plus généralement, la manière dont ces approches traitent de ces situations se révèle parfois inadaptée.

Dans cette thèse, nous nous sommes intéressés à la prédiction des variations brusques et importantes de la production. Des antécédents ont montré que la manifestation d'erreurs temporelles dans la prédiction de ces variations peut présenter un certain risque vis-à-vis d'une gestion sûre et économique du système électrique. Les estimations traditionnelles du niveau de production peuvent échouer à capturer l'incertitude temporelle qui entoure la prédiction de ces événements. Face à la demande des gestionnaires de réseaux et autres acteurs, le développement d'approches dédiées à leur prédiction a vu l'apparition d'une représentation plus adaptée de cette incertitude. Nos efforts de recherche s'inscrivent dans la lignée de ces travaux. Ils ont eu pour but de formaliser et d'améliorer la représentation et l'estimation de l'incertitude temporelle associée à la prédiction des variations brusques et importantes de la production éolienne.

L'incertitude temporelle associée à la prédiction d'une variation suppose l'existence d'instants caractéristiques chez cette dernière. Chercher à les définir nous a amenés à considérer leur relativité aux échelles de temps et à la géométrie d'une variation. Les moyens grâce auxquels la variabilité de la production est aujourd'hui décrite ne s'intéressent pas à ces aspects. En étudiant les travaux de la littérature de traitement du signal et de détection de ruptures, nous avons présenté certains outils permettant de caractériser les aspects géomé-

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

triques d'une variation. Il nous ont permis d'introduire des notions qui à notre connaissance étaient encore inconnues du domaine éolien : comme la recherche d'une géométrie particulière de rupture par l'élaboration de filtres adaptés, ou encore l'estimation de paramètres géométriques à travers la réponse d'un filtre à différentes échelles.

La caractérisation des variations brusques et importantes de la production éolienne nécessitait d'étudier l'adéquation des outils présentés. Nous avons ainsi proposé une méthodologie visant à évaluer différentes approches de caractérisation d'une rupture. Nous avons défini un modèle de rupture permettant de représenter les aspects borné et non-stationnaire du processus de production, ainsi que la nature aléatoire avec laquelle se succèdent les variations brusques d'un signal de production. Nous avons également introduit des critères permettant d'évaluer de manière quantitative les performances d'une approche de détection. A partir de simulations issues de notre modèle et des critères proposés, nous avons comparé les performances de filtres et d'approches utilisés dans la littérature éolienne et de traitement du signal. Notre travail a ainsi permis de replacer les pratiques rencontrées dans la littérature éolienne, vis-à-vis de ce qui se fait dans l'état de l'art en traitement du signal. Nous avons notamment pu constater l'inadéquation dans la détection des ruptures d'un signal, d'un filtre dont l'utilisation est largement répandue dans la littérature éolienne. L'utilisation qui est faite des informations recueillies à différentes échelles, à travers certaines approches de la littérature éolienne et de traitement du signal, n'est pas non plus appropriée.

Pour prédire l'instant d'apparition d'une rupture dans un signal de production nous avons développé une approche reposant sur l'utilisation de scénarii de la production. Dans l'approche proposée, l'estimation de l'instant d'apparition d'une rupture provient de l'agrégation des estimations réalisées à travers différents scénarii. Dans nos travaux, les scénarii en question proviennent de la conversion en puissance de prévisions météorologiques ensemblistes. Initialement, notre approche a été testée à partir d'un unique modèle de conversion en puissance. Cependant, son développement doit lui permettre de pouvoir s'adapter aux caractéristiques suivant lesquelles un modèle de conversion en puissance prédit les caractères brusque et important des variations de la production. Pour estimer l'incertitude associée, nous avons proposé l'utilisation d'intervalles de confiance temporels et de probabilités d'observation associées. L'utilisation d'intervalles permet de représenter correctement la possibilité de ne pas observer une rupture prédite. Le conditionnement des probabilités d'observation au nombre de membres prédisant une rupture permet quant à lui d'exploiter la propriété de résolution des ensembles.

Nous avons évalué notre approche à partir de données de production provenant de trois fermes Françaises, couvrant une période suffisamment longue pour obtenir des résultats exploitables. A travers l'évaluation de notre approche, nous avons pu évaluer les performances du modèle de prévisions ensemblistes EPS de ECMWF, dans la prédiction des variations brusques et importantes de la production éolienne. Nous avons ainsi pu montrer, que les ensembles résultant du modèle EPS offrent un taux de capture des ruptures supérieur à celui du membre de contrôle. Nos résultats montrent que ce gain ne s'accompagne en revanche pas d'une plus grande précision de prédiction. En particulier, les ruptures effectivement pré-

dites sont généralement moins bien localisées. L'estimation conditionnelle de l'incertitude par les ensembles offre des prédictions généralement fiables dont les performances sont supérieures à celles de la climatologie.

Dans le cadre du projet Européen de recherche SAFEWIND¹ dans lequel s'inscrit cette thèse, notre approche a été implémentée sous forme de prototype opérationnel. Elle a ainsi pu être testée dans des conditions réelles sur 41 fermes totalisant plus de 320 MW de capacités de production réparties entre la France, et l'île de Crète en Grèce. Ce travail a démontré la faisabilité d'implémenter la méthode en un outil opérationnel utilisable par les gestionnaires de réseaux, et a permis des interactions directes avec les industriels sur son utilité et sur les perspectives d'intégration dans les outils de prise de décision. De manière générale, les résultats préliminaires obtenus se sont montrés probants. Actuellement en cours d'approfondissement, ces résultats pourront être consultés dans un des rapports du projet [1] et feront potentiellement l'objet d'une future publication.

5.2 Perspectives

Les perspectives de notre travail sont multiples. En premier lieu, notre approche de prédiction, aussi bien que toute autre approche dédiée à l'étude des caractéristiques des variations brusques et importantes de la production, pourraient bénéficier de futurs développements relatifs aux approches de détection de ruptures. Nous avons présenté dans cette thèse des approches reposant sur des procédures locales de sélection d'échelle qui obéissent à deux paradigmes opposés. Dans le premier, il s'agit de déterminer une échelle localement fiable la plus petite possible (cf [2]). Tandis que dans le second, il s'agit de déterminer une échelle la plus grande possible sans que la détection d'une rupture ne souffre des interactions dues à la présence de ruptures voisines (cf [3]). Dans le premier, la présence de ruptures voisines n'est pas explicitement prise en compte, alors que dans le second la procédure de sélection d'échelle repose généralement sur une heuristique. Une étude plus formelle des propriétés de cette dernière, dans laquelle la nature aléatoire avec laquelle deux ruptures dans un signal peuvent se succéder, pourrait constituer un développement intéressant.

Dans notre approche de prédiction, les caractéristiques (i.e. instants) des ruptures prédites par différents membres d'un ensemble sont regroupées suivant une heuristique. On étudie pour cela les variations d'une fonctionnelle définie comme étant la somme du nombre de membres prédisant une rupture à chaque instant. Notre approche pourrait certainement bénéficier de l'introduction d'une procédure de lissage visant régulariser l'étude des variations de cette fonctionnelle. Une approche similaire, où la position de certains points structuraux communs à un ensemble de courbes est donnée par les modes d'une fonction de densité estimée par noyau, a été proposée dans [4]. Une autre problématique (que l'on retrouve dans [4]), vient du nombre souvent très faible de membres (resp. de courbes) à partir duquel estimer l'instant d'apparition d'une rupture (resp. la position de points structuraux). Etendre

1. www.safewind.eu

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

notre approche d'estimation de manière à ce qu'elle repose, pour chaque membre, sur l'utilisation de plusieurs échelles, pourrait conduire à des estimations plus fiables (un peu comme l'approche développée dans [5] sous le nom d'"intensité structurelle").

Au-delà de la fiabilité de ces estimations, l'utilisation de plusieurs échelles devrait permettre d'assurer la détection des ruptures les plus proches. Toutefois, l'incertitude temporelle associée à la prédiction de ces dernières pourrait, du fait de leur proximité, nécessiter une représentation plus adéquate. L'utilisation de plusieurs échelles pourrait également permettre l'estimation d'autres paramètres caractéristiques d'une rupture (e.g. amplitude, lissage...), vis-à-vis desquels développer notre approche de prédiction.

Un autre point méritant une attention particulière concerne les aspects propres à l'utilisation de notre approche d'un point de vue opérationnel. Les lentes variations du climat se manifestant à des échelles de temps de plusieurs mois à plusieurs années, sont très certainement responsables de changements dans les processus entraînant l'apparition de variations brusques et importantes de la production. La probabilité d'apparition de ces dernières doit ainsi varier au cours du temps, et nécessiter une forme d'estimation adaptative. Si comme nous avons pu le proposer cette estimation repose sur un modèle logistique, une forme d'estimation récursive des paramètres du modèle pourrait s'avérer efficace. A notre connaissance, une telle forme d'estimation pour ce modèle en particulier n'a été encore que peu traitée dans la littérature (une méthode a récemment été proposée dans [6]).

Enfin, il est nécessaire d'étudier comment la nouvelle forme de prédictions que nous avons introduite pourrait se révéler utile dans les divers processus de décision. Ceci soulève différentes questions. Comment les estimations développées, associées aux estimations traditionnelles entourant la prédiction des variations brusques et importantes de la production, doivent-elles être intégrées dans ces processus ? Se révèlent-t-elles être d'une quelconque valeur en termes économiques ou de sécurité dans la gestion du réseau ? En quoi peuvent-elles se substituer ou compléter l'information déjà fournie par les ensembles ? Peuvent-elles participer (sous leur forme actuelle) à la mise en place de réserves adaptées, permettant de mieux gérer l'équilibre offre/demande face aux contraintes de flexibilité imposées par la réactivité des ressources conventionnelles [7] ?

Bibliographie

- [1] P. Brandt and A. Bocquet. Evaluation of the operational phase. Technical report, Safewind project. Deliverable Dp-8.5. [Available online : www.safewind.eu], 2012.
- [2] J.H. Elder and S.W. Zucker. Local scale control for edge detection and blur estimation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 20(7) :699–716, jul 1998.
- [3] T. Lindeberg. Edge detection and ridge detection with automatic scale selection. *International Journal of Computer Vision*, 30(2) :117–154, 1998.
- [4] T. Gasser and A. Kneip. Searching for structure in curve samples. *Journal of the American Statistical Association*, 90(432) :1179–1188, 1995.
- [5] J. Bigot. *Recalage de signaux et analyse de variance fonctionnelle par ondelettes. Applications au domaine biomédical*. PhD thesis, Université Joseph-Fourier-Grenoble 1. [Available online : <http://tel.archives-ouvertes.fr/docs/00/04/60/08/PDF/tel-00004362.pdf>], 2003.
- [6] T.H. McCormick, A.E. Raftery, D. Madigan, and R.S. Burd. Dynamic logistic regression and dynamic model averaging for binary classification. *Biometrics*, 68(1) :23–30, 2012.
- [7] N. Navid and G. Rosenwald. Market solutions for managing ramp flexibility with high penetration of renewable resource. *Sustainable Energy, IEEE Transactions on*, 3(4) :784–790, oct. 2012.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

Annexe A

Prédiction de l'instant d'apparition d'une rupture - Résultats d'autres cas d'étude

A.1 Contenu des résultats

Nous donnons ici les résultats de prédiction de l'instant d'apparition d'une rupture dans les signaux de production obtenus pour deux autres fermes. Ces fermes (désignées par "ferme N°2" et "ferme N°3") sont cette fois situées en terrain plat. Les données météorologiques, algorithmes de prédiction et périodes de temps utilisés pour l'apprentissage et l'évaluation des prédictions sont les mêmes pour chacune des fermes considérées. Nous donnons ici :

- Le compromis "précision / capture" dans la prédiction des variations brusques et importantes de la production, à partir des ensembles et du membre de contrôle (Figures A.1 et A.4).
- Les performances associées aux prédictions ponctuelles de l'instant d'apparition d'une rupture (Figures A.2 et A.5).
- La fiabilité et la finesse des probabilités destinées à estimer l'incertitude associée (Figures A.3 et A.6).
- Le gain de performances, provenant du conditionnement de ces probabilités au nombre de membres prédisant une rupture, vis-à-vis de la climatologie (Tables A.1 et A.2).

Nous donnons d'abords les résultats issus de la ferme N°2, puis ceux issus de la ferme N°3.

A.2 Ferme N°2




FIGURE A.1 – Courbes paramétrées par $\hat{\tau}$ (dont certaines valeurs ont été représentées ici par des chiffres), représentant la précision de prédiction des variations brusques et importantes de la production par le membre de contrôle et les ensembles, en fonction du taux de capture. Les résultats montrés ici ont été obtenus pour des ruptures d'intensité minimale $\tau = 30\% P_n$, prédites à partir de l'approche d'agrégation **A2**, et pour un rayon d'intervalle $\delta = 8$ h.

Prédiction de l'instant d'apparition d'une rupture - Résultats d'autres cas d'étude

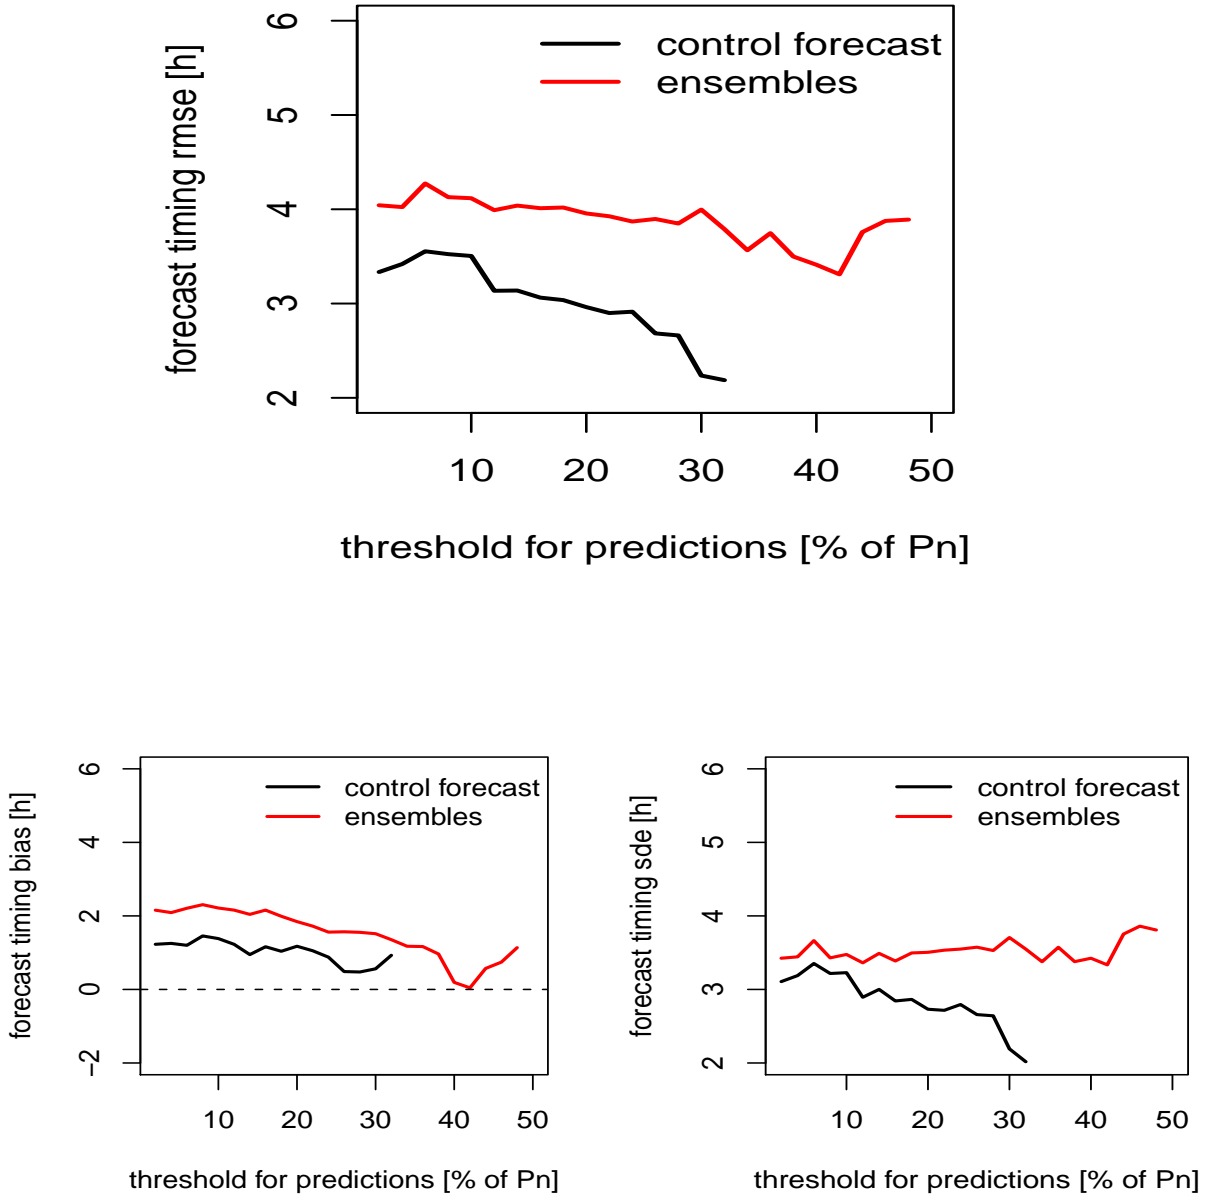


FIGURE A.2 – Racine carré de l'erreur quadratique moyenne (graphe du haut), erreur moyenne (graphe en bas à gauche) et écart-types (graphe en bas à droite) des erreurs associées aux prédictions ponctuelles de l'instant d'apparition d'une rupture dans un signal de production. Les résultats montrés ici ont été obtenus pour des ruptures d'intensité minimale $\tau = 30\% P_n$, à partir de l'approche d'agrégation **A2**, et pour un rayon d'intervalle $\delta = 8 h$.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

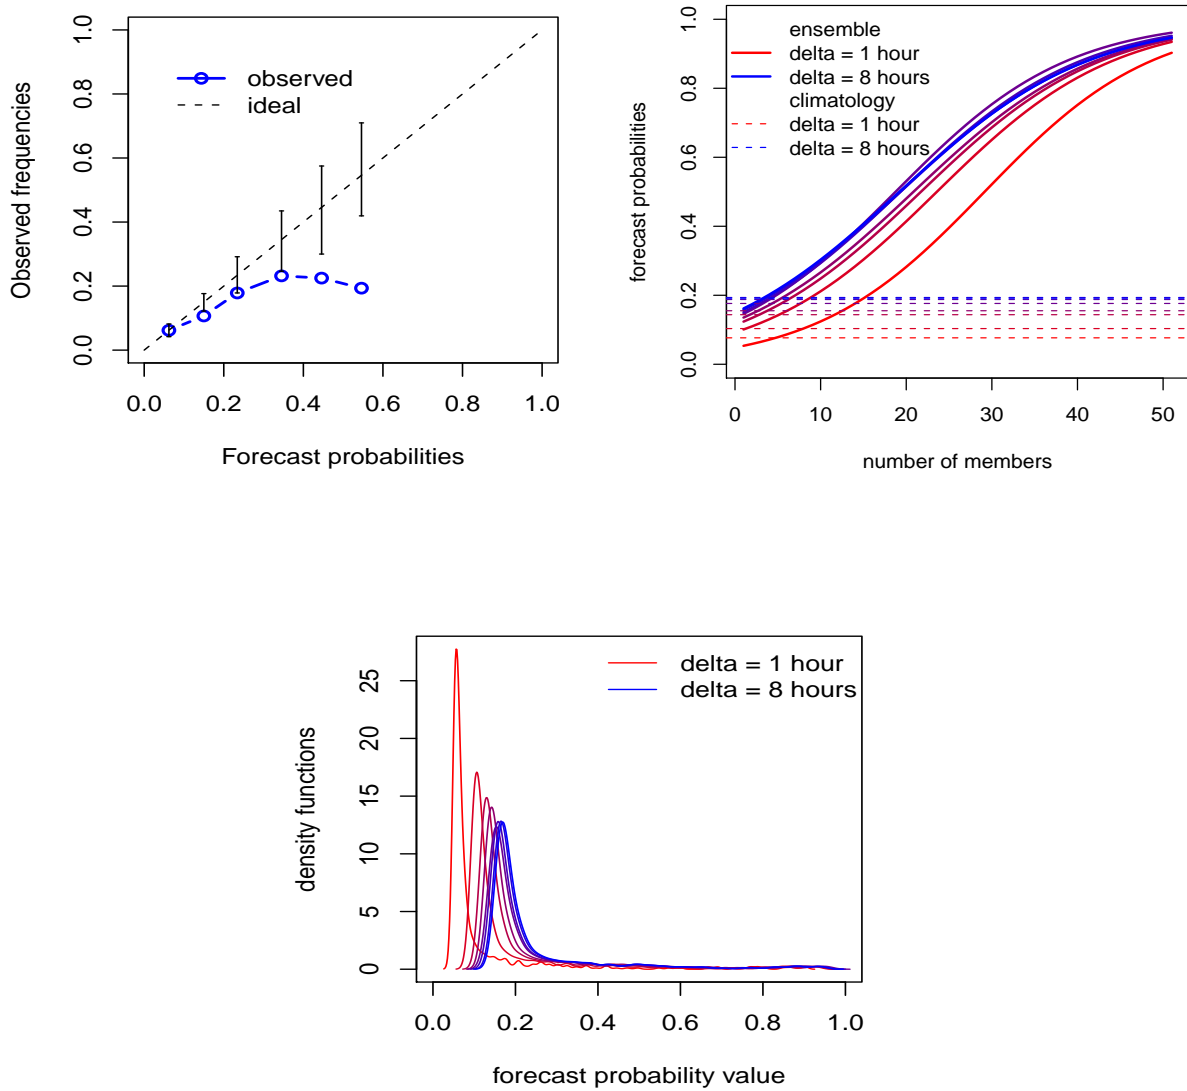


FIGURE A.3 – Diagramme de fiabilité (en haut à gauche), valeurs en fonction du nombre de membres m (en haut à droite), et distribution (en bas) des probabilités prédites $p_{\delta,m}$ d'apparition d'une rupture dans les intervalles temporels I_{δ} . Les résultats montrés ici ont été obtenus avec l'approche d'agrégation **A2**, un seuil $\hat{\tau} = 30\% P_n$ et un modèle de régression logistique.

Prédiction de l'instant d'apparition d'une rupture - Résultats d'autres cas d'étude

TABLE A.1 – Brier skill score BSS_{clim} (en pourcentages) vis-à-vis de la climatologie, des prédictions probabilistes de l'instant d'apparition d'une rupture par les ensembles dans les intervalles I_δ (δ en heures). Les résultats sont donnés à la fois pour l'approche d'agrégation **A1** et pour l'approche **A2**, pour des probabilités estimées suivant un modèle logistique (log. reg.), et un estimateur de Nadarya-Watson (N.W.).

$\hat{\tau}$ ($\%P_n$)	log. reg.			N.W.		
	$\delta = 2$	$\delta = 5$	$\delta = 8$	$\delta = 2$	$\delta = 5$	$\delta = 8$
Clustering approach A1						
10	10.6 (2.1)	14.6 (2.2)	16.6 (2.6)	10.6 (2.1)	13.6 (2.4)	16.2 (2.8)
20	7.6 (5.8)	12.5 (4.7)	11.1 (4.6)	10.2 (4.3)	14.3 (3.5)	13.8 (3.5)
30	-7 (9.5)	0.9 (5.8)	0.5 (5.2)	2.3 (6.5)	5.5 (4.2)	4.8 (3.8)
40	-14.3 (13.0)	-6.2 (9.2)	-5.6 (8.2)	-4.4 (9.5)	0.3 (7.1)	-1.2 (6.6)
Clustering approach A2						
10	6.5 (2.7)	11.2 (2.6)	9.2 (2.4)	6.1 (1.9)	10.9 (1.9)	8.8 (1.8)
20	-1.5 (5.7)	8.9 (4.2)	6.2 (3.8)	5.5 (3.3)	11.5 (2.7)	9.0 (2.5)
30	-6.4 (8.3)	-0.2 (5.4)	0.6 (4.7)	3.3 (5.1)	4.7 (3.6)	4.4 (3.2)
40	-13.0 (12.8)	-4.8 (9.0)	-4.2 (7.7)	-2.7 (9.1)	1.9 (6.8)	1.0 (5.8)

A.3 Ferme N°3




FIGURE A.4 – Courbes paramétrées par $\hat{\tau}$ (dont certaines valeurs ont été représentées ici par des chiffres), représentant la précision de prédiction des variations brusques et importantes de la production par le membre de contrôle et les ensembles, en fonction du taux de capture. Les résultats montrés ici ont été obtenus pour des ruptures d'intensité minimale $\tau = 30\% P_n$, prédites à partir de l'approche d'agrégation A2, et pour un rayon d'intervalle $\delta = 8$ h.

Prédiction de l'instant d'apparition d'une rupture - Résultats d'autres cas d'étude




FIGURE A.5 – Racine carré de l'erreur quadratique moyenne (graphe du haut), erreur moyenne (graphe en bas à gauche) et écart-types (graphe en bas à droite) des erreurs associées aux prédictions ponctuelles de l'instant d'apparition d'une rupture dans un signal de production. Les résultats montrés ici ont été obtenus pour des ruptures d'intensité minimale $\tau = 30\% P_n$, à partir de l'approche d'agrégation **A2**, et pour un rayon d'intervalle $\delta = 8 h$.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

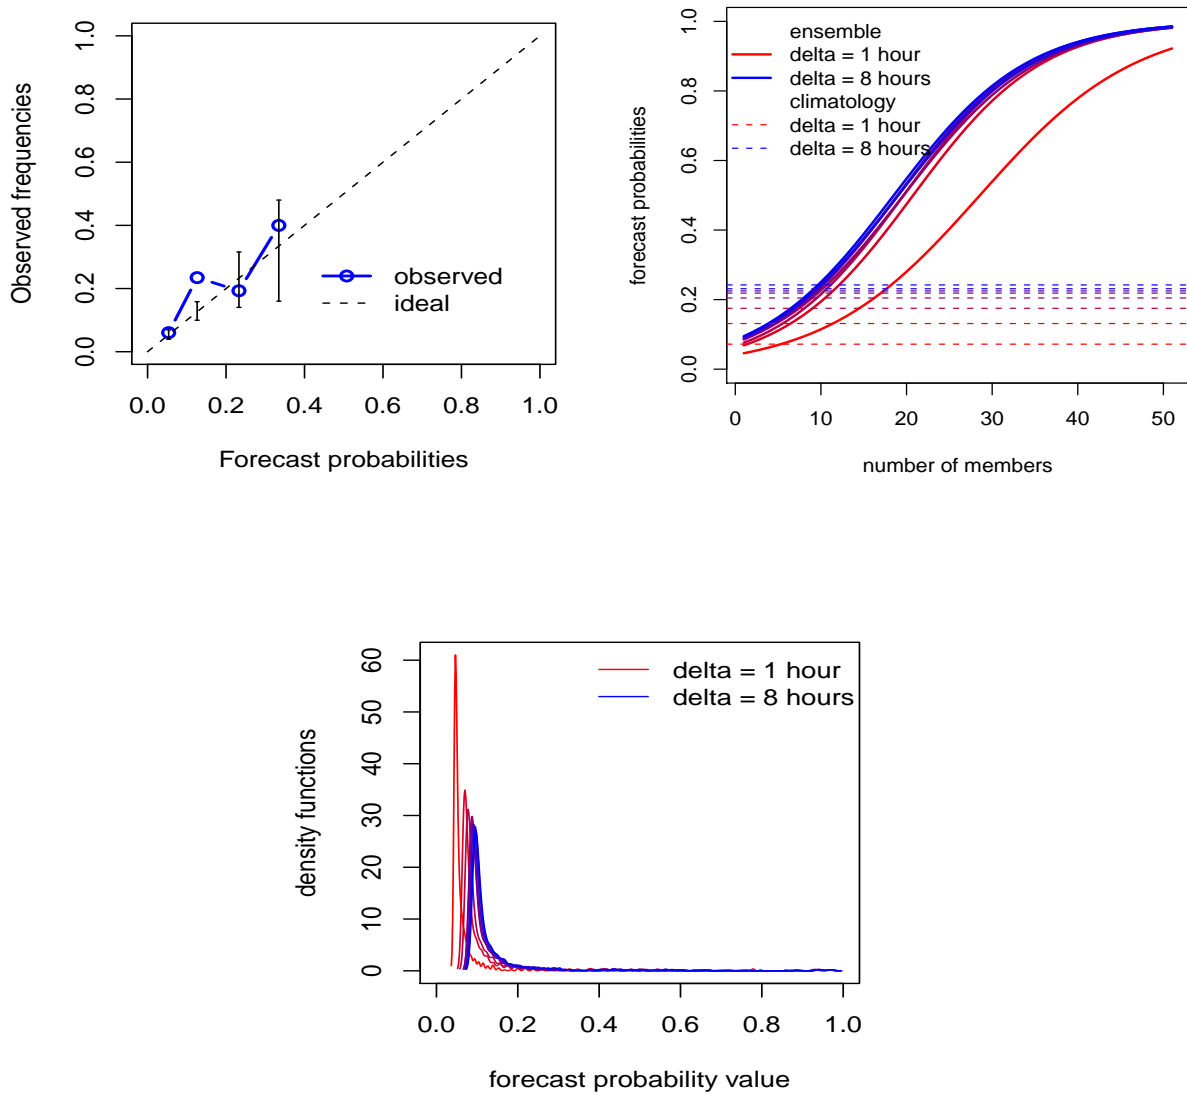


FIGURE A.6 – Diagramme de fiabilité (en haut à gauche), valeurs en fonction du nombre de membres m (en haut à droite), et distribution (en bas) des probabilités prédites $p_{\delta,m}$ d'apparition d'une rupture dans les intervalles temporels I_{δ} . Les résultats montrés ici ont été obtenus avec l'approche d'agrégation **A2**, un seuil $\hat{\tau} = 30\% P_n$ et un modèle de régression logistique.

Prédiction de l'instant d'apparition d'une rupture - Résultats d'autres cas d'étude

TABLE A.2 – Brier skill score BSS_{clim} (en pourcentages) vis-à-vis de la climatologie, des prédictions probabilistes de l'instant d'apparition d'une rupture par les ensembles dans les intervalles I_δ (δ en heures). Les résultats sont donnés à la fois pour l'approche d'agrégation **A1** et pour l'approche **A2**, pour des probabilités estimées suivant un modèle logistique (log. reg.), et un estimateur de Nadarya-Watson (N.W.).

$\hat{\tau}$ ($\%P_n$)	log. reg.			N.W.		
	$\delta = 2$	$\delta = 5$	$\delta = 8$	$\delta = 2$	$\delta = 5$	$\delta = 8$
Clustering approach A1						
10	7.1 (2.4)	12.1 (1.7)	14.1 (1.8)	7.9 (2.4)	12.0 (2.1)	15.2 (2.1)
20	9.7 (3.3)	12.7 (2.7)	12.8 (2.6)	9.8 (2.7)	12.0 (2.4)	12.3 (2.4)
30	1.4 (4.2)	4.6 (3.2)	2.3 (3.3)	1.6 (4.2)	4.2 (3.3)	0.8 (3.4)
40	-0.7 (9.1)	5.5 (4.2)	1.3 (4.9)	2.9 (10.6)	5.5 (6.2)	-0.1 (6.7)
Clustering approach A2						
10	3.9 (1.4)	6.2 (1.3)	5.5 (1.2)	3.7 (1.3)	5.9 (1.2)	5.3 (1.2)
20	3.5 (2.9)	7.7 (2.3)	7.2 (2.2)	5.1 (2.4)	8.2 (2.1)	7.4 (2.0)
30	-0.3 (3.8)	2.4 (3.0)	0.5 (2.9)	-0.1 (3.8)	2.0 (3.1)	-1.9 (3.0)
40	-0.5 (9.0)	5.3 (4.0)	1.4 (4.7)	3.8 (11.0)	6.6 (5.7)	1.2 (6.2)

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

Annexe B

Liste des publications

Publications dans des journaux de rang A

1. A. Bossavy, R. Girard and G. Kariniotakis. "Forecasting ramps of wind power production using numerical weather prediction ensembles", *Wind Energy*, pages n/a-n/a, 2012. DOI : 10.1002/we.526

Publications dans des conférences internationales

2. A. Bossavy, R. Girard, and G. Kariniotakis. « Forecasting uncertainty related to ramps of wind power production ». In *Scientific Proceedings of the European Wind Energy Conference, EWEC 2010*, Warsaw, Poland, 2010. (Présentation orale)
3. A. Bossavy, R. Girard and G. Kariniotakis. « A probabilistic approach to forecast ramps of wind power production using ensembles », *European Meteorological Society Annual Meeting 2011*, Berlin, Allemagne, 2011. (Poster)
4. R. Girard, A. Bossavy and G. Kariniotakis. « Forecasting ramps of wind power production at different time scales ». In *Proceedings of the European Wind Energy Conference, EWEC 2011*, Brussels, Belgium, 2011. (Présentation orale)

Récompenses

Le poster 3. présenté à la conférence EMS a été récompensé par un prix de meilleur poster.

Caractérisation et prédiction des variations brusques et importantes de la production éolienne

Caractérisation et prédiction probabiliste des variations brusques et importantes de la production éolienne

RESUME : L'énergie éolienne est aujourd'hui la source d'énergie renouvelable en plus forte expansion. Le caractère variable et partiellement contrôlable de sa production complexifie la gestion du système électrique. L'utilisation dans divers processus de décision, de prédictions du niveau de production à des horizons de 2-3 jours, permet une meilleure intégration de cette ressource. Certaines situations donnent néanmoins lieu à des performances de prédiction insatisfaisantes. Des erreurs dans la prédiction de l'instant d'apparition de variations brusques et importantes de la production, peuvent être responsables d'importants déséquilibres énergétiques, et avoir un impact négatif sur la gestion du système électrique. L'objectif de cette thèse est de proposer des approches permettant d'une part de caractériser ces variations, et d'autre part de prédire et d'estimer l'incertitude dans l'instant de leur apparition. Dans un premier temps, nous étudions différentes formes de caractérisation de ces variations. Nous proposons un modèle de rupture permettant de représenter le caractère aléatoire dans la proximité des ruptures d'un signal, tout en tenant compte des aspects borné et non-stationnaire du processus de production. A partir de simulations issues de ce modèle, nous réalisons une étude paramétrique destinée à évaluer et comparer les performances de différents filtres et approches multi-échelles de détection. Dans un deuxième temps, nous proposons une approche de prédiction probabiliste de l'instant d'apparition d'une rupture, reposant sur l'utilisation de prévisions météorologiques ensemblistes. Leur conversion en puissance fournit différents scénarii de la production, à partir desquels sont agrégées les prédictions de l'instant d'apparition d'une rupture. L'incertitude associée est représentée à l'aide d'intervalles de confiance temporels et de probabilités estimées conditionnellement. Nous évaluons la fiabilité et la finesse de ces estimations sur la base de mesures de production provenant de différentes fermes éoliennes.

Mots clés : énergie éolienne, détection de ruptures, incertitude temporelle, prédiction probabiliste, prévisions météorologiques ensemblistes, prévision des rampes

Characterization and probabilistic forecasting of wind power production ramps

ABSTRACT : Today, wind energy is the fastest growing renewable energy source. The variable and partially controllable nature of wind power production causes difficulties in the management of power systems. Forecasts of wind power production 2-3 days ahead can facilitate its integration. Though, particular situations result in unsatisfactory prediction accuracy. Errors in forecasting the timing of large and sharp variations of wind power can result in large energy imbalances, with a negative impact on the management of a power system. The objective of this thesis is to propose approaches to characterize such variations, to forecast their timing, and to estimate the associated uncertainty. First, we study different alternatives in the characterization of wind power variations. We propose an edge model to represent the random nature of edge occurrence, along with representing appropriately the bounded and non-stationary aspects of the wind power production process. From simulations, we make a parametric study to evaluate and compare the performances of different filters and multi-scale edge detection approaches. Then, we propose a probabilistic forecasting approach of edge occurrence and timing, based on numerical weather prediction ensembles. Their conversion into power provides an ensemble of wind power scenarios from which the different forecast timings of an edge are combined. The associated uncertainty is represented through temporal confidence intervals with conditionally estimated probabilities of occurrence. We evaluate the reliability and resolution of those estimations based on power measurements from various real world case studies.

Keywords : wind energy, edge detection, temporal uncertainty, probabilistic forecasting, numerical weather prediction ensembles, ramps forecasting