
Détection et prédiction de défaillances dans un parc d'éoliennes à l'aide de réseaux bayésiens

Toader GHERASIM¹, Bouthayna ED-DAHMOUNI¹,
Philippe LERAY¹

Laboratoire d'Informatique de Nantes Atlantique, LINA UMR 6241, Université de Nantes

Nantes, France

toader.gherasim@univ-nantes.fr, eddahmouni.bouthayna@gmail.com, philippe.leray@univ-nantes.fr

RÉSUMÉ. Dans le domaine de la production d'énergie éolienne, une des pistes les plus prometteuses pour la maîtrise des coûts en phase opérationnelle passe par la prédiction et la détection précoce des défaillances. Dans cette étude nous présentons une première approche qui se veut réaliste et applicable facilement sur des données réelles. Notre approche repose sur l'utilisation de réseaux bayésiens et essaie d'utiliser l'ensemble des informations qui remontent des outils de surveillance et de gestion des parcs d'éoliennes : informations SCADA spécifiques au fonctionnement de chaque éolienne, informations qui concernent la ferme dans son ensemble et informations de maintenance.

ABSTRACT. In the field of wind energy, the prediction and early detection of wind turbine failures is one of the most promising ways to control and optimize the operational costs. In this paper we present the main ideas of a new approach that is realistic and easily applicable on real data. Our approach is based on the use of several Bayesian networks and tries to exploit most of the different types of data produced by monitoring systems of a wind farm.

MOTS-CLÉS : éolienne, détection de défaillances, réseau Bayésien

KEYWORDS: wind turbine, failure detection, Bayesian networks

1. Contexte

L'essor des énergies renouvelables, parmi lesquelles l'éolien occupe une place de choix, est l'une des évolutions économiques et sociétales majeures de ces dernières décennies. Aujourd'hui, l'un des principaux freins au développement des champs éoliens, et particulièrement des champs offshore, demeure l'incertitude quant à leur rentabilité économique. En effet, la maîtrise des coûts de production est beaucoup plus complexe par rapport à une installation classique (thermique, hydraulique ou nucléaire). La nature même des parcs d'éoliennes explique en grande partie cette complexité.

Dans un champ d'éoliennes la production électrique est assurée par un nombre élevé de petits générateurs (<10 MW pour les plus puissants) qui sont exposés à des nombreux aléas (vibrations, variations brusques de charge, de température et d'humidité, etc.), alors que dans une installation classique la production électrique est assurée par un nombre réduit de gros générateurs (plusieurs centaines ou milliers de MW), qui fonctionnent dans des environnements parfaitement maîtrisés. Comme, pour des raisons de coût, les éoliennes sont en général moins instrumentées (et donc moins surveillées) que les installations classiques, l'évolution de l'état de leurs composants est moins bien connue, ce qui fait que la manière de les exploiter et de les entretenir n'est pas toujours optimisée. L'ensemble de ces faits font augmenter de manière significative le risque d'apparition soudaine de défaillances dans les parcs éoliens par rapport aux installations classiques. La durée d'indisponibilité et les coûts de maintenance corrective associés à ces défaillances soudaines sont difficilement prévisibles (WWEA, 2012). En plus, pour les parcs offshore, certaines opérations de maintenance peuvent nécessiter une organisation logistique lourde et très coûteuse (hélicoptères, bateaux spéciaux qu'il faut réserver plusieurs mois en avance, etc.).

Le retour d'expérience au sujet de l'exploitation des parcs offshore reste encore très limité et l'adaptation des connaissances et des pratiques de l'éolien onshore vers l'offshore n'est pas aisée au vu des différences de conditions environnementales et surtout d'organisation logistique des opérations de maintenance.

Dans l'état actuel de développement du domaine, on peut donc considérer que les coûts en phase opérationnelle et principalement ceux de maintenance sont mal maîtrisés, voire peu connus pour les parcs d'éoliennes en général et pour les parcs offshore en particulier.

2. Problématique

Dans ce contexte, une des pistes les plus prometteuses pour la maîtrise des coûts en phase opérationnelle concerne le développement d'outils d'aide à la prédiction et à la détection précoce des défaillances. En effet, la prédiction et la détection précoce facilitent l'optimisation des opérations de maintenance et permettent donc d'en maîtriser et réduire les coûts. L'optimisation des opérations de maintenance inclut, parmi

d'autres aspects, le développement de la maintenance préventive, le regroupement des interventions et la constitution de stocks de pièces de rechange.

Les éoliennes sont des machines complexes et sont sujet à des défaillances très diversifiées dont la détection (et encore plus la prédiction) peuvent nécessiter une expertise technique très pointue. La compréhension des défaillances et la détermination de leurs causes nécessitent souvent des connaissances solides dans plusieurs domaines comme la mécanique, l'électrotechnique, l'électronique, etc.

Certaines de ces défaillances arrivent souvent, d'autres très rarement. Certaines défaillances sont critiques, impliquant l'arrêt de l'éolienne, alors que certaines autres défaillances permettent à l'éolienne de fonctionner, éventuellement en mode dégradé (bridage de la vitesse de rotation, de la puissance produite, etc.). Certaines défaillances peuvent être corrigées facilement et pour pas cher, d'autres coûtent très cher. Certaines défaillances sont prédictibles (comme celles due à l'usure mécanique de certains composants), d'autre sont soudaines, non prédictibles (la défaillance de certains composants électroniques). Certaines défaillances sont facilement détectables, d'autres très difficilement.

Bien que moins surveillées que les installations traditionnelles de production d'électricité, la plupart des éoliennes de taille moyenne ou grande sont équipées de systèmes SCADA qui gèrent leur fonctionnement et enregistrent toute une série des données concernant le fonctionnement de l'éolienne (températures, pressions, vitesses de rotation, niveaux de vibrations, paramètres électriques, etc.). Les paramètres surveillés et les données enregistrées peuvent varier très fortement d'un modèle d'éolienne à un autre, mais il existe un socle minimal qui est commun à la plupart des systèmes. Très souvent les informations enregistrées sont envoyées, en partie ou dans leur intégralité, en continu ou de manière régulière, à un certain intervalle de temps, à des centres de commande et contrôle des parcs éoliens. Parfois, en plus des systèmes SCADA installées par le fabricant, les exploitants installent des systèmes de surveillances complémentaires, comme, par exemple, des systèmes de mesure et d'analyse des vibrations.

L'analyse des données qui arrivent aux centres de commande et de contrôle, éclairée par l'expertise sur la manière dont l'éolienne est conçue et fonctionne, et sur les caractéristiques de ses composants, permet la détection d'une partie significative des défaillances et même la prédiction de quelques unes (prédiction basée sur l'observation de l'évolution de certains signaux dans les données). Néanmoins, certaines défaillances ne sont pas détectables ou prédictibles en s'appuyant seulement sur l'analyse des données qui remontent de façon automatique.

Dans cette étude nous abordons d'un point de vue pragmatique la problématique de l'automatisation de la prédiction et de la détection de défaillances et nous proposons une première approche qui se veut directement applicable sur des données réelles. Bien évidemment, notre approche ne se veut pas exhaustive et ne permettra pas détecter ou prédire tous les types de défaillances possibles.

3. État de l'art

De nombreuses études ont été consacrées ces dernières années à la problématique de l'automatisation de la prédiction, de la détection et du diagnostic des défaillances des éoliennes (Kim *et al.*, 2011 ; Marquez *et al.*, 2012 ; Chen, Hao, 2012 ; Yang *et al.*, 2013 ; 2014). Parmi les méthodes les plus prometteuses on peut citer l'analyse continue, itérative, à l'aide de différentes techniques, des données remontant des systèmes de surveillance et de contrôle de l'éolienne (Schlechtingen *et al.*, 2013 ; Schlechtingen, Santos, 2014 ; Marquez *et al.*, 2012).

Depuis presque deux décennies les Réseaux Bayésiens (RB) se sont imposés comme l'un des outils les plus adaptés pour modéliser des systèmes complexes afin d'en faire leur diagnostic, d'étudier leur fiabilité ou de prédire leur évolution (Weber *et al.*, 2012). En effet, plusieurs caractéristiques intrinsèques des RB s'avèrent particulièrement utiles pour la modélisation nécessaire dans des problématiques rencontrées dans la vie réelle.

Tout d'abord, grâce à leur nature de modèles graphiques probabilistes ils sont facilement visualisables et les relations graphiques entre les variables sont faciles à interpréter et modifier par des experts du domaine. Ensuite, ils permettent d'intégrer dans le même modèle des connaissances ayant des natures (qualitative ou quantitative), des origines (experts, données historiques, etc.) et des degrés d'abstraction différents. Ils prennent en compte intrinsèquement l'incertitude et peuvent fonctionner avec des données incomplètes en entrée.

Une des extensions des RB, les Réseaux Bayésiens Dynamiques (*DBN - Dynamic Bayesian Network*) (Murphy, 2002), permet de modéliser l'évolution temporelle de systèmes complexes (Weber, Jouffe, 2003 ; Donat *et al.*, 2010).

4. Notre approche

A la différence des méthodes d'apprentissage de réseaux bayésiens à partir de données, nous nous intéressons ici à une approche où le modèle est construit à partir des nombreuses expertises disponibles. Pour prédire ou détecter les défaillances d'une éolienne, deux visions ainsi sont possibles. D'une part, on peut considérer une éolienne comme un système indépendant, constitué d'un ensemble de composants dont l'état évolue dans le temps (approche *bottom-up*). Chaque défaillance de l'éolienne correspond à la défaillance d'un ou de plusieurs de ses composants. L'état de l'éolienne est une agrégation des états de l'ensemble de ses composants.

D'autre part, on peut considérer une éolienne comme une partie d'un parc éolien (McLaughlin, 2009). Les éoliennes d'un même parc subissent les mêmes conditions météorologiques et des corrélations fortes existent entre les caractéristiques du vent qu'elles reçoivent (vitesse du vent, densité de l'air, turbulences). En regardant l'ensemble du parc à un instant donné et en tenant compte des corrélations existantes il est possible de détecter des anomalies dans le comportement d'une éolienne et d'en déduire la présence d'une défaillance (approche *top-down*).

Nous proposons d'intégrer ces deux visions dans le cadre d'une approche hybride, en modélisant à l'aide de RB non seulement une éolienne mais le parc dans son ensemble. En intégrant dans le modèle du parc tous les modèles qui correspondent aux éoliennes membres du parc nous obtenons un modèle capable d'exploiter en même temps les corrélations entre les éoliennes et les signaux présents dans les données SCADA spécifiques à chaque éolienne.

Dans la suite nous présentons d'abord notre modèle de prédiction et de détection qui est spécifique à chaque éolienne (modèle *bottom-up*). Dans un deuxième temps nous présentons un modèle de ferme dans lequel peuvent être intégrées les instances de modèle correspondant aux éoliennes membres du parc.

4.1. Modélisation *bottom-up*

Pour détecter et prédire les défaillances (ou les pannes) les experts ne se limitent pas à l'analyse des données qui remontent à un moment donné d'une éolienne mais analysent un historique plus ou moins long, s'intéressent aux opérations de maintenance déjà réalisées et font appel à un large éventail de connaissances métier qui concernent les signatures des différentes pannes dans les données, les signes précurseurs, les retours d'expérience sur la fiabilité des composants, etc. Souvent, les signatures des pannes ne sont pas directement visibles dans les données qui proviennent de l'éolienne mais seulement après différents pré-traitements plus ou moins complexes, pré-traitements qui peuvent aller de la simple détection du dépassement d'un seuil à une analyse vibratoire très poussée.

Nous faisons la supposition que l'ensemble de ces connaissances métier sont disponibles sur la forme d'un ensemble de règles reliant les défaillances à des composants de l'éolienne et à des différentes signatures qui leur correspondent dans les données. Comme ces règles résumant les connaissances métier peuvent varier d'un type d'éolienne à un autre, le modèle de détection et prédiction proposé est spécifique à chaque type d'éolienne.

Dans un souci de simplicité nous supposons également que l'analyse des données remontant des éoliennes est effectuée séparément, indépendamment de notre modèle, et que celui-ci fera appel directement aux résultats ainsi obtenus et formalisés sur une forme binaire : présence ou absence d'une certaine signature dans les données durant un intervalle de temps donné.

Pour construire notre modèle nous associons à chacun des composants de l'éolienne une variable aléatoire correspondant à l'état interne, caché, du composant. Pour limiter la complexité du modèle nous considérons, dans cette première approche, que ces variables peuvent prendre seulement trois valeurs : (1) *OK* – le composant fonctionne parfaitement; (2) *dégradé* – le composant continue de fonctionner mais en dehors des paramètres nominaux, remplissant seulement en partie son rôle; et (3) *KO* – le composant ne fonctionne plus, il ne remplit plus son rôle. Pour certains types de composants qui ne peuvent pas fonctionner de manière dégradée (par exemple les

composants électroniques) la variable associée accepte seulement les valeurs *OK* et *KO*.

Plusieurs défaillances distinctes peuvent concerner un même composant et il est possible que seulement une partie de ces défaillances aient associé une signature dans les données remontant à partir du système de surveillance de l'éolienne. Chacune des défaillances associées à un composant correspondent soit à son état *dégradé*, soit à son état *KO*. Si plusieurs défaillances correspondent à une même valeur de la variable *état composant* alors, dans cette première version, notre modèle permet de détecter (et respectivement prédire) uniquement jusqu'au niveau de ce groupe de défaillances sans pouvoir préciser la défaillance exacte.

Comme l'état des composants évolue dans le temps (ils vieillissent, se dégradent et tombent en panne au bout d'un certain temps), de manière irréversible (ils ne se réparent jamais seuls, leur état ne peut être amélioré que suite à une opération de maintenance), dans notre modèle les variables *état* associées aux composants sont des variables dynamiques d'ordre 1. Ainsi, le modèle que nous construisons est un Réseau Bayésien Dynamique d'ordre 1. Les probabilités conditionnelles $P(\text{état_composant}(t) \mid \text{état_composant}(t-1))$ sont construites en prenant en compte les retours d'expérience sur la fiabilité et la durée de vie des composants.

La valeur d'une variable *état composant* n'est jamais observée de manière directe mais peut être déduite à partir de la présence, ou respectivement l'absence, dans les données des signatures correspondant aux différentes pannes associées au composant.

A chaque variable *état composant*, nous associons donc une série de variables booléennes *signature défaillance*, chacune de ces variables correspondant à la signature d'une panne possible du composant. Ces signatures peuvent indiquer soit l'existence d'une panne, soit la possibilité qu'elle apparaisse au bout d'un certain temps. Les paramètres des chacune des variables *signature défaillance* ont été estimés manuellement, à l'aide des experts, en prenant en compte la nature de la panne associée et les caractéristiques du signal (associé à une ou plusieurs pannes, conséquence directe ou indirecte, signal simple ou composé). Par exemple, pour un signal simple, conséquence directe d'une seule panne, nous avons estimé que $P(\text{signal} \mid \text{panne}) = 0.99$ et $P(\text{signal} \mid \text{sans panne}) = 0.005$.

Notre modèle contient finalement une variable *état éolienne* ayant trois valeurs possibles : *OK*, *dégradé* et *KO*. Cette variable est une agrégation de type *LeakyNoisyMax* (Diez, Druzdzal, 2007), l'état de l'éolienne étant défini par l'état de son composant le plus dégradé. Une probabilité de fuite, estimée par expertise, permet aussi d'indiquer que l'éolienne peut être en panne même si aucun de ses composants de notre modèle n'est en panne.

4.2. Modélisation top-down

Dans un parc, les éoliennes ne reçoivent presque jamais exactement le même vent. Cela s'explique à la fois par la topologie du parc (présence de reliefs qui freinent ou




Figure 1. Illustration de la structure du modèle bottom-up.

accélèrent les courants ou créent des turbulences), par les différences de rugosité du sol (ou de la surface de la mer) mais aussi par le positionnement relatif des éoliennes (elles peuvent freiner le vent et générer des turbulences qui seront vues par les éoliennes en aval), bien que, lors de la conception du parc les éoliennes sont positionnées de sorte à minimiser leur influences réciproques pour les directions de vent dominantes.

Les rapports entre la vitesse de vent vue par une éolienne et une vitesse de vent de référence au niveau du parc (vitesse mesurée par un mât, par exemple) peuvent être calculés à l'aide de modèles micro-météorologiques. Ces rapports (ou indices de corrélation) varient en fonction de la direction et de la vitesse du vent et sont spécifiques à chaque éolienne du parc. Nous considérons que ces indices de corrélation sont pré-calculés et disponibles pour les parcs que nous voulons modéliser.

Pour construire le modèle de prédiction et de détection de défaillances qui exploite les corrélations existantes entre les éoliennes d'un même parc nous distinguons deux types de variables : celles qui concernent des caractéristiques globales du parc et celles qui concernent une éolienne en particulier.

Dans notre modèle nous avons deux variables globales (*Vitesse vent champ* et *Direction vent*) et des groupes de 5 variables associées à chacune des éoliennes du parc : (1) la *vitesse vent mesurée* par le capteur de l'éolienne ; (2) la *vitesse vent calculée* à partir de la *vitesse champ* à l'aide des indices de corrélation ; (3) la *puissance* instantanée produite par l'éolienne ; (4) l'*état* du capteur qui mesure la vitesse du vent ; (5) l'*état de l'éolienne*.

Les variables *état éolienne* sont communes aux modèles *bottom-up* et *top-down* et permettent l'intégration des modèles spécifiques à chaque éolienne dans le modèle du parc obtenant ainsi un modèle global de détection et de prédiction des défaillances.

Toutes les variables de notre modèle sont des variables discrètes. La discrétisation de la vitesse du vent et de la puissance produite sont dépendantes du type et de la puissance des éoliennes qui composent le parc. Les liens entre les différentes variables du modèle sont visibles dans la figure 2.

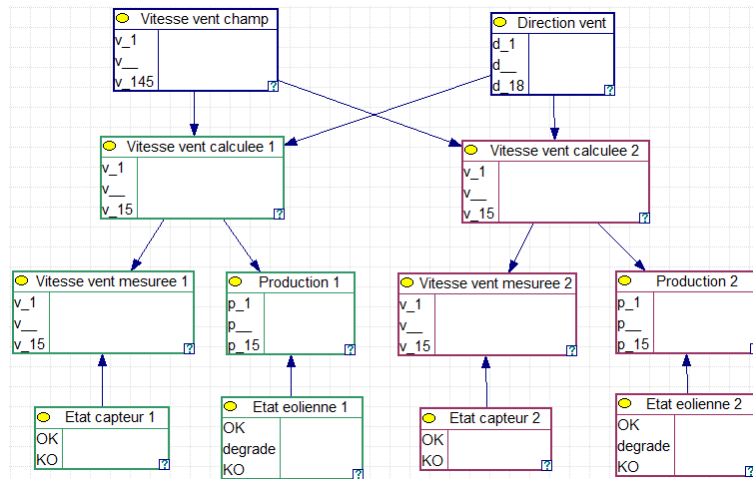


Figure 2. Modèle top-down correspondant à un parc composé de deux éoliennes.

5. Expérimentations sur des données réelles

Les deux parties de notre modèle ont été implémentées à l'aide la plate-forme logicielle PILGRIM¹ développée au sein du LINA et de la librairie ProBT².

La validation de notre modèle, construit à partir d'expertises, passe par une confrontation à la réalité terrain. En l'état actuel du projet, seule la partie *top-down* a été testée sur un jeu de données réelles provenant d'un parc installé dans le sud de la France et composé de 10 éoliennes de 0.7 MW chacune. Le jeu de données couvre une période de 24 mois (février 2013 - janvier 2015) et contient, pour chacune des éoliennes, les valeurs moyennes sur 10 minutes de 10 paramètres surveillés par le système SCADA - en tout 105120 lignes. Nous disposons également de l'historique météo (vitesse et direction du vent sur le champ) et de l'historique des opérations de pilotage manuel (arrêts imposés, bridage) et de maintenance effectuées sur chacune de éoliennes pendant cette période.

Pour cette première phase de validation, nous nous sommes concentrés sur une sous-partie de ces données (64696 sur les 105120) pour lesquelles nous possédons toutes les informations terrain. Notre objectif ici est de "cacher" une partie des variables du modèle, et de confronter comment notre modèle va prédire ces variables

1. <http://pilgrim.univ-nantes.fr/>

2. <http://www.probayes.com/fr/Bayesian-Programming-Book/downloads/>

par rapport aux données terrain à notre disposition. Les premières variables "cachées" sont des variables que notre modèle cherchera plus tard à prédire (*État éolienne i*, *État capteur i*). D'autres sont plutôt des entrées futures de notre modèle (*Vitesse champ* et *Direction vent*).

Nous avons ainsi fourni en entrée les valeurs des variables *Vitesse vent mesurée i* et *Production i*, et obtenu par inférence probabiliste les distributions de probabilité des variables *État éolienne i*, *État capteur i*, *Vitesse champ* et *Direction vent*.

Pour la variable *État éolienne i* notre modèle a bien détecté tous les cas où une des éoliennes était en panne (ou en arrêt imposé manuellement). Toutes les situations de bridage manuel ont également bien été identifiées. Néanmoins, dans 23% des cas où le modèle aurait dû détecter (probabilité la plus élevée) que l'éolienne était OK, fonctionnant dans les paramètres nominaux, conformément à l'historique à notre disposition, il a détecté que l'éolienne fonctionnait en mode *dégradé*.

Pour la variable *État capteur i* aucune panne n'a été détectée (ce qui correspond bien à l'historique). Notre modèle arrive à retrouver la variable discrète *Vitesse champ* avec une précision de 62% (même valeur discrétisée) ou de 87% (valeur discrétisée voisine de un ou deux intervalles).

Notre modèle n'arrive pas à retrouver la valeur de la variable *Direction vent* : seulement 16% de bonnes détections. En effet, la ferme à laquelle correspondent les données semble avoir des comportements similaires pour plusieurs directions du vent, rendant difficile l'identification du sens du vent à partir des variables observées.

Cette première série d'expériences nous conforte sur la première partie de notre modèle (*top-down*), mettant en évidence de bonnes propriétés en terme de prédiction de l'état d'une éolienne (ce qui est notre objectif principal), même s'il reste un nombre élevé de faux positifs pour la détection du mode *dégradé*.

6. Conclusion et perspectives

Dans cet article, nous avons décrit une modélisation à partir de réseaux bayésiens pour la détection et la prédiction des défaillances des éoliennes. La première partie de notre modèle considère une éolienne comme un système indépendant, constitué d'un ensemble de composants dont l'état évolue dans le temps (approche *bottom-up*). La seconde partie *top-down* considère une éolienne comme une partie d'un parc éolien, et utilise plutôt la dimension spatiale du système.

Une première série d'expériences a permis de confronter le modèle *top-down* à des données réelles, mettant en évidence de bonnes propriétés en terme de prédiction de l'état d'une éolienne, même s'il reste un nombre élevé de faux positifs pour la détection du mode *dégradé*.

Dans la suite de notre travail nous voulons tester la partie *bottom-up* de notre modèle sur le même jeu de données et vérifier dans quelle mesure il permet de détecter et de prédire les défaillances qui se sont produites pendant cette période. Nous souhai-

tons aussi voir si l'utilisation conjointe des deux parties du modèle permet d'améliorer la détection de l'état de chaque composant, et de diminuer le nombre de faux positifs identifiés dans les premières expériences.

Par la suite, ces modèles seront utilisés pour prédire l'état des composants de chaque éolienne à différents instants, à l'aide d'algorithmes classique d'inférence probabiliste dans les réseaux bayésiens dynamiques comme l'algorithme Interface (Murphy, 2002).

Bibliographie

- Chen J., Hao G. (2012). Research on the fault diagnosis of wind turbine gearbox based on bayesian networks. In Y. Wang, T. Li (Eds.), *Practical applications of intelligent systems: Proc. of the 6th int. conf. on intelligent systems and knowledge engineering (ISKE2011)*, p. 217–223. Shanghai, China, Springer Berlin Heidelberg.
- Diez F., Druzdzel M. (2007, avril). *Canonical probabilistic models for knowledge engineering*. Rapport technique n° CISIAD-06-01. Madrid, Spain, UNED.
- Donat R., Leray P., Bouillaut L., Aknin P. (2010). A dynamic bayesian network to represent discrete duration models. *Neurocomputing*, vol. 73, n° 4–6, p. 570–577.
- Kim K., Parthasarathy G., Uluyol O., Foslien W., Sheng S., Fleming P. (2011). Use of scada data for failure detection in wind turbines. In *Proc. of 5th int. conf. on energy sustainability, aug 7-10*. Washington, D.C., USA, ASME - American Society of Mechanical Engineers.
- Marquez F. P. G., Tobias A. M., Pérez J. M. P., Papaelias M. (2012). Condition monitoring of wind turbines: Techniques and methods. *Renewable Energy*, vol. 46, p. 169 - 178.
- McLaughlin D. (2009). Wind farm performance assessment: experience in the real world. In *In: Renewable energy world conference and expo europe; 26–28 may, 2009*. Cologne, Germany, KoelnMesse.
- Murphy K. (2002). *Dynamic bayesian networks: Representation, inference and learning*. Thèse de doctorat non publiée, University of california, Berkeley.
- Schlechtingen M., Santos I. F. (2014). Wind turbine condition monitoring based on SCADA data using normal behavior models. part 2: Application examples. *Applied Soft Computing*, vol. 14, Part C, p. 447 - 460.
- Schlechtingen M., Santos I. F., Achiche S. (2013). Wind turbine condition monitoring based on SCADA data using normal behavior models. part 1: System description. *Applied Soft Computing*, vol. 13, n° 1, p. 259 - 270.
- Weber P., Jouffe L. (2003). Reliability modelling with dynamic bayesian networks. In *Proc. of 5th IFAC symposium on fault detection, supervision and safety of technical processes (SAFEPROCESS'03)*, p. 57–62. Washington, D.C., USA, IFAC.
- Weber P., Medina-Oliva G., Simon C., Iung B. (2012). Overview on bayesian networks applications for dependability, risk analysis and maintenance areas. *Engineering Applications of Artificial Intelligence*, vol. 25, n° 4, p. 671–682.
- WWEA. (2012, oct). Quarterly bulletin. *World Wind Energy Association Bulletin*, p. 1–40.

- Yang W., Court R., Jiang J. (2013). Wind turbine condition monitoring by the approach of SCADA data analysis. *Renewable Energy*, vol. 53, p. 365 - 376.
- Yang W., Tavner P., Crabtree C., Feng Y., Qiu Y. (2014). Wind turbine condition monitoring: technical and commercial challenges. *Wind Energy*, vol. 17, n° 5, p. 673–693.