

Détection, diagnostic et pronostic pour les éoliennes :  
développement de modèles basés sur l'autoencodeur  
variationnel utilisant des données SCADA

par

Adaiton MOREIRA DE OLIVEIRA FILHO

THÈSE PAR ARTICLES PRÉSENTÉE À L'ÉCOLE DE TECHNOLOGIE  
SUPÉRIEURE COMME EXIGENCE PARTIELLE À L'OBTENTION  
DU DOCTORAT EN GÉNIE  
Ph.D.

MONTRÉAL, LE 15 JUILLET 2024

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE  
UNIVERSITÉ DU QUÉBEC



Adaiton Moreira de Oliveira Filho, 2024



Cette licence Creative Commons signifie qu'il est permis de diffuser, d'imprimer ou de sauvegarder sur un autre support une partie ou la totalité de cette œuvre à condition de mentionner l'auteur, que ces utilisations soient faites à des fins non commerciales et que le contenu de l'œuvre n'ait pas été modifié.

**PRÉSENTATION DU JURY**

CETTE THÈSE A ÉTÉ ÉVALUÉE

PAR UN JURY COMPOSÉ DE:

M. Antoine Tahan, directeur de thèse  
Département de génie mécanique à l'École de technologie supérieure

M. Francis Pelletier, codirecteur  
Power Factors

M. Ali Gharbi, président du jury  
Département de génie des systèmes à l'École de technologie supérieure

M. Jean-Pierre Kenné, membre du jury  
Département de génie mécanique à l'École de technologie supérieure

M. Hussein Ibrahim, examinateur externe indépendant  
Centre national intégré du manufacturier intelligent

M. Yves Gagnon, examinateur externe indépendant  
Université de Moncton

ELLE A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 18 JUIN 2024

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE



## AVANT-PROPOS

Cette thèse par articles présente les recherches menées par M. Oliveira Filho, ing., M. Sc., dans le cadre du doctorat en génie au Département de génie mécanique de l'ÉTS. La recherche doctorale a été réalisée entre janvier 2021 et juin 2024 et s'inscrit dans les collaborations entre les chercheurs du Département de génie mécanique de l'ÉTS et l'entreprise Power Factors, avec la collaboration des chercheurs de l'Institut de Recherche d'Hydro-Québec (IREQ). Le projet a été cofinancé par Power Factors et Mitacs via les programmes Mitacs Globalink cycles supérieurs (IT24180) et Mitacs Accélération (IT22958).

Cette recherche doctorale est motivée par le besoin industriel de modèles pour appuyer des stratégies d'opération et de maintenance (O&M, *Operation and Maintenance*) optimales pour les éoliennes, visant notamment l'augmentation du taux de disponibilité et la réduction des coûts d'O&M. L'accent est mis sur le développement d'outils d'analyse utilisant des données du système de contrôle et d'acquisition de données (SCADA, *Supervisory Control and Data Acquisition*) et des modèles d'intelligence artificielle (IA, *Artificial Intelligence*) interprétables.

Dans le cadre du doctorat, M. Oliveira Filho a été le premier auteur de trois articles de journaux avec comité de lecture :

- Article 1 Oliveira-Filho, A., Zemouri, R., Cambron, P., & Tahan, A. (2023). Early Detection and Diagnosis of Wind Turbine Abnormal Conditions Using an Interpretable Supervised Variational Autoencoder Model. *Energies*, 16(12), 4544. Adresse DOI : <https://doi.org/10.3390/en16124544>
- Article 2 Oliveira-Filho, A., Zemouri, R., Pelletier, F., & Tahan, A. (2024). System Condition Monitoring Based on a Standardized Latent Space and the Nataf Transform. *IEEE Access*. Adresse DOI : <https://doi.org/10.1109/ACCESS.2024.3370949>
- Article 3 Oliveira-Filho, A., Zemouri, R., Pelletier, F., & Tahan, A. (2024). Remaining Useful Life Estimation Based on Variational Autoencoder Latent Space Representation : Application to Wind Turbines. Article soumis à *IEEE Transactions on Reliability*.



## **REMERCIEMENTS**

Je tiens à exprimer ma gratitude envers ceux et celles qui m'ont épaulé et encouragé pendant le parcours académique qui m'a amené à vous présenter cette thèse de doctorat.

Je remercie chaleureusement mon directeur de thèse, Antoine Tahan, pour son encadrement attentif, encourageant et stimulant pendant les années du doctorat. Son expertise, sa bonne humeur et sa reconnaissance de mon travail ont contribué à créer un environnement de recherche très positif et fructueux. Ma reconnaissance s'étend à mes co-directeurs de thèse de chez Power Factors, Philippe Cambron et Francis Pelletier. Leurs expertises dans les éoliennes ont été cruciales pour cette thèse. Un grand merci à Ryad Zemouri, notre collaborateur de l'IREQ. Son expertise sur les modèles d'intelligence artificielle, en particulier les modèles à variables latentes, a grandement enrichi cette thèse. Je leur adresse donc un grand merci pour leurs précieuses contributions, conseils avisés et encouragements.

Je suis également reconnaissant envers l'équipe du projet Alliance pour leurs critiques constructives et suggestions, qui ont joué un rôle crucial dans l'avancement de nos travaux. Un remerciement spécial à mes collègues doctorants pour leur camaraderie.

Un grand merci à Power Factors, à Mitacs et à Antoine Tahan pour la confiance et le soutien financier apportés à notre recherche. Je tiens à remercier les membres du jury pour le temps accordé à la lecture et à l'évaluation de cette thèse.

Je conclus avec des remerciements personnels. Je dois une fière chandelle aux femmes de ma famille : Nilda, Nunila, Karemme et Pabline. Merci aussi à Fernando, Vitor, Benício, Henrique et Mario. Un merci affectueux à toutes celles et à tous ceux grâce à qui Montréal est devenu mon chez-moi : merci Ryan ! merci Gabi, Bia, Marcela, Nathália, Boris, Steven et Sacha.



# **Détection, diagnostic et pronostic pour les éoliennes : développement de modèles basés sur l'autoencodeur variationnel utilisant des données SCADA**

Adaiton MOREIRA DE OLIVEIRA FILHO

## **RÉSUMÉ**

Les éoliennes sont une des solutions technologiques clés pour la transition énergétique. Une augmentation significative de la puissance éolienne installée dans le monde au cours des prochaines décennies est préconisée pour limiter le changement climatique et ses conséquences. La « Prévision de transition énergétique jusqu'en 2050 » (DNV, 2023) estime que la puissance éolienne installée mondiale devrait être multipliée par un facteur 8 entre 2022 et 2050. Les ambitions d'augmentation du taux de pénétration de l'énergie éolienne à l'échelle globale dépendent de la continuité des tendances de baisse du coût actualisé de l'énergie (LCOE) éolienne. Une des voies pour atteindre cette condition est l'adoption de stratégies optimales pour l'opération et la maintenance (O&M) des éoliennes, visant notamment l'augmentation du taux de disponibilité et la réduction des dépenses d'O&M.

À ce jour, les opérateurs analysent l'état de santé des éoliennes à partir des données provenant du système de contrôle et d'acquisition de données (SCADA), présent par défaut dans les éoliennes modernes. La quête pour des stratégies d'O&M optimales motive des recherches dans le domaine du pronostic et la gestion de l'état de santé (PHM). Le processus d'analyse PHM comprend plusieurs étapes, notamment la détection, le diagnostic et le pronostic. Les modèles résultant de ces analyses apportent des informations pour guider la prise de décisions concernant l'O&M, notamment pour orienter des interventions telles que des inspections et des réparations. Des modèles pour la détection et le diagnostic d'anomalies de l'opération sont plutôt bien développés et largement utilisés chez les opérateurs des parcs éoliens, tandis que le modèle de pronostic pose encore des défis scientifiques et techniques. Aussi, même si les modèles d'intelligence artificielle (IA) présentent un grand potentiel pour améliorer les performances des méthodes pour l'analyse de l'état de santé des éoliennes, leur usage est freiné par le manque d'interprétabilité.

Dans ce contexte, cette recherche a investigué l'implémentation du processus d'analyse PHM utilisant des données du système SCADA et des modèles d'IA interprétables. En particulier, la recherche s'est tâchée de détecter des anomalies plus tôt que les méthodes courantes, à diagnostiquer un état dégradé parmi les multiples conditions de santé, et à établir un modèle de pronostic pour les éoliennes. La recherche a priorisé des modes de dégradation impactant les composants critiques des éoliennes, en particulier le générateur, la boîte de vitesses, le roulement principal et les pales.

Une base de données SCADA couvrant plus de deux ans d'opération sur environ 120 éoliennes est utilisée pour bâtir et valider les approches proposées. Les investigations ont conduit à choisir la classe des modèles d'IA à variables latentes (LVM), à l'instar de l'autoencodeur variationnel (VAE). Un modèle supervisé, l'autoencodeur variationnel associé à un classificateur (VAEC), permet de projeter l'espace physique de haute dimension des mesures SCADA dans un espace latent de dimensionnalité réduite. L'espace latent est tel que la position géographique du point

projeté informe sur la condition d'opération de l'éolienne. L'espace latent du VAEC s'avère représentatif de la condition physique des éoliennes, ce qui permet la définition d'indicateurs de santé pertinents. De surcroît, l'espace peut être défini avec la dimension 2 pour fournir un outil de visualisation commode qui apporte de l'interprétabilité aux approches proposées. Les résultats obtenus ont abouti dans trois articles scientifiques.

Le premier article présente le modèle VAEC et démontre son usage pour l'analyse et la représentation visuelle des données SCADA. Une nouvelle approche de surveillance de l'état de santé des éoliennes à partir de l'espace latent du VAEC est introduite. L'indicateur de santé (HI) combine la distance de Mahalanobis par rapport à la distribution de la condition saine dans l'espace latent avec la charte de contrôle de la moyenne mobile pondérée exponentiellement (EWMA). Des études de cas réelles démontrent que l'approche permet de détecter des anomalies avant le système de contrôle associé au système SCADA et des approches basées sur des modèles de régression. Ce premier article démontre l'usage du classificateur du VAEC pour le diagnostic des éoliennes. Les études de cas illustrent le potentiel de l'outil de visualisation intégré pour améliorer l'interprétabilité et la confiance dans les résultats du modèle.

Le deuxième article introduit une nouvelle approche de surveillance de l'état des systèmes complexes basée sur une représentation standardisée de l'espace latent du VAEC. Une contribution originale de cet article est d'utiliser la transformation isoprobabiliste de Nataf pour mapper l'espace latent dans un espace standardisé. Dans l'espace standard de Nataf, la condition saine suit la distribution gaussienne centrée réduite, ce qui permet la définition de deux HI complémentaires et la définition de seuils appropriés à partir d'un niveau de confiance prédéfini. De surcroît, l'usage de la transformée de Nataf réduit la sensibilité de l'approche aux hyperparamètres pendant le processus d'apprentissage. L'implémentation sur deux études de cas démontre le potentiel de l'approche proposée et sa capacité à détecter des anomalies plus tôt que des approches concurrentes. Premièrement, l'approche a été appliquée à la base de données du simulateur de moteur d'avion (C-MAPSS) de la NASA. La deuxième étude de cas porte sur une base comprenant des mesures SCADA d'éoliennes modernes comprenant des multiples classes d'opération anormale. Ce deuxième article a également démontré l'utilisation de l'espace latent et de l'espace standard de Nataf comme outils de visualisation, en suivant l'évolution des distributions de points dans ces deux espaces.

Le troisième article propose une approche pour estimer la durée de vie restante (RUL) à partir de l'espace latent du VAEC projetant les données SCADA. La projection des ensembles de données orientées temporellement dans l'espace latent produit des trajectoires informant sur l'évolution de l'état du système au fil du temps. Une modélisation cinématique et une régularisation appropriée permettent de décrire la projection dans l'espace latent comme une trajectoire lisse dans l'espace bidimensionnel. L'approche utilise l'expansion de Taylor et la méthode de Monte-Carlo pour estimer, avec un critère définissant la fin de la vie utile (EOL) dans l'espace latent, la densité de probabilité de la RUL. L'application à des cas d'étude de dégradation *post-mortem* de composants éoliens montre la cohérence entre la RUL estimée et celle de référence.

En conclusion, cette thèse présente des approches innovantes pour la détection, le diagnostic et le pronostic des éoliennes à partir des données SCADA, en utilisant un modèle d'IA interprétable. Les trois articles proposés démontrent l'utilisation du modèle VAEC pour l'analyse des relations complexes entre les mesures SCADA. L'espace latent du VAEC a permis d'implémenter le processus d'analyse PHM pour les éoliennes tout en mettant l'accent sur l'interprétabilité des modèles pour faciliter la compréhension et l'adoption par les opérateurs, analystes et techniciens. Les résultats démontrent l'efficacité des indicateurs de santé définis à partir de l'espace latent, permettant une détection précoce des anomalies et un diagnostic précis. Le modèle de pronostic proposé, basé sur une projection en trajectoire dans l'espace latent, offre une estimation fiable de la durée de vie résiduelle des éoliennes. Ces contributions techniques, en plus des retombées scientifiques, posent les bases pour le développement de solutions informatiques pouvant être intégrées aux outils de suivi de performance des éoliennes, favorisant ainsi le transfert technologique et l'application industrielle des approches développées. Les produits de la recherche ont donc le potentiel de soutenir les décisions relatives à l'O&M des éoliennes afin de réduire les coûts tout en augmentant la fiabilité et la disponibilité des installations.

Le dernier chapitre de la thèse présente des recommandations pour les recherches futures ainsi que pour le transfert technologique et le déploiement des méthodes proposées.

**Mots-clés:** éoliennes, données SCADA, suivi de l'état de santé, détection, diagnostic, pronostic, réseaux de neurone profonds, modèles à variables latentes, autoencodeur variationnel, systèmes complexes, outil de visualisation



# **Detection, Diagnosis, and Prognosis for Wind Turbines: Development of Variational Autoencoder-Based Models Using SCADA Data**

Adaíton MOREIRA DE OLIVEIRA FILHO

## **ABSTRACT**

Wind turbines are among the key technological solutions for energy transition. A significant increase in the wind energy installed capacity worldwide is advocated to limit climate change and its consequences. For instance, the "Energy Transition Outlook to 2050" (DNV, 2023) estimates that the global wind energy installed capacity should increase eightfold between 2022 and 2050. Increasing the penetration rate of wind energy globally relies on the continuation of the trend of decreasing the Levelized Cost of Energy (LCOE) of this source. This can be achieved by increasing availability rates and reducing operation and maintenance (O&M) expenditures of wind turbines through optimal O&M strategies.

Operators currently analyze the health condition of wind turbines using data from the built-in Supervisory Control and Data Acquisition (SCADA) system. The quest for optimal O&M strategies motivates research in the field of Prognostics and Health Management (PHM). The PHM analysis comprises the detection, the diagnosis, and the prognosis of abnormal conditions. The models resulting from these analyses provide information to guide decision-making regarding O&M, especially in situ interventions such as inspections and repairs. Models for detecting and diagnosing operational anomalies are well developed and widely used in wind farm operation. In contrast, prognosis models still pose scientific and technical challenges. Additionally, the lack of interpretability hinders the use of AI models in the analysis of wind turbine health conditions despite their proven potential.

In this context, this research investigates the implementation of the PHM analysis using SCADA data and interpretable AI models. Specifically, it sought to detect anomalies earlier than current methods, diagnose degraded conditions among multiple health conditions, and establish a prognostic model for wind turbines. The research is focused on degradation modes on critical wind turbine components, namely the generator, gearbox, main bearing, and blades.

A SCADA database comprising more than two years of operation and nearly 120 wind turbines was used to develop and validate the proposed approaches. This research introduced PHM analysis using Latent Variable Models (LVM), which are variations of the Variational Autoencoder (VAE) model. A supervised LVM, the Variational Autoencoder Embedded with Classifier (VAEC), projects the high-dimensional physical space of SCADA measurements into a low-dimensional latent space. The geographical position of the projected point in the latent space informs the operational condition of the wind turbine. The latent space of the VAEC is representative of the physical condition of wind turbines, allowing the definition of relevant health indicators. Furthermore, the space can be defined in 2D to provide a convenient visualization tool that adds interpretability to the proposed approaches.

The first paper presents the VAEC model and demonstrates its use for the analysis and visual representation of SCADA data. It introduces a new approach aiming at the health condition monitoring of wind turbines using the VAEC latent space. The Health Index (HI) uses the Mahalanobis distance and the exponentially weighted moving average (EWMA) control chart. Real case studies show that this approach can detect anomalies earlier than the SCADA control system and regression-based approaches. This first paper also demonstrates the use of the VAEC classifier for diagnosing abnormal operating conditions in wind turbines. Case studies illustrate the potential of the integrated visualization tool to improve interpretability and confidence in the model results.

The second paper introduces a new approach for monitoring the health condition of complex systems based on a standardized representation of the VAEC latent space. An original contribution of this paper is the use of the Nataf isoprobabilistic transform to map the latent space into a standardized space. In the Nataf standard space, the healthy condition follows the standard normal distribution, allowing the definition of two complementary HIs and appropriate thresholds based on a predefined confidence level. Moreover, the use of the Nataf transform reduces the approach's sensitivity to hyperparameters during the learning process. The implementation in two case studies demonstrates the potential of the proposed approach and its ability to detect anomalies earlier than competing approaches. First, the approach was applied to NASA's Commercial Modular Aero-Propulsion System Simulation (C-MAPSS) database. The second case study involves a database with SCADA measurements from modern wind turbines, including multiple abnormal operation classes. The second paper also demonstrates the use of the latent space and the Nataf standard space as visualization tools, tracking the evolution of probability distributions within the latent and the Nataf spaces.

The third paper proposes an approach to estimate the remaining useful life (RUL) from the VAEC latent space projecting the SCADA data. The projection of time-oriented datasets defines trajectories in the latent space. Such trajectories inform about the evolution of the system's health condition. The latent space projection is described as a smooth trajectory by using kinematic modelling and an appropriate regularization method. The approach uses Taylor expansion and the Monte Carlo method to estimate the RUL probability density, with a criterion defining the end of useful life (EOL) in the latent space. Application to post-mortem degradation case studies of wind turbine components shows consistency between the estimated and ground-truth RUL.

In conclusion, this thesis presents innovative AI approaches for the detection, diagnosis, and prognosis of wind turbines using SCADA data. The proposed AI model is interpretable via a built-in visualization tool. The three proposed papers demonstrate the use of the VAEC model for analyzing the complex behaviour described by SCADA measurements. The VAEC latent space enabled the implementation of the PHM analysis process for wind turbines while emphasizing model interpretability to facilitate understanding and adoption by operators, analysts, and technicians. The results demonstrate the effectiveness of health indicators defined from the latent space, in particular for early anomaly detection and accurate diagnosis. The proposed prognosis model, based on the trajectory projected in the latent space, provides a reliable estimation of the wind turbines' remaining useful life. These technical contributions, in addition to the

scientific outcomes, lay the foundation for developing software solutions that can be integrated into wind turbine performance monitoring tools. Thereby, it can facilitate technological transfer and the industrial application of the proposed approaches. The outcomes of the research can support decision-making related to the O&M of wind turbines, potentially contributing to the reduction of costs and the increase of reliability and availability. The final chapter of the thesis presents recommendations for future research, for the technological transfer and deployment of the proposed methods.

**Keywords:** wind turbines, SCADA data, condition monitoring, detection, diagnosis, prognosis, deep neural networks, latent variable models, variational autoencoder, complex systems, visualization tool



## TABLE DES MATIÈRES

	Page
<b>INTRODUCTION .....</b>	<b>1</b>
<b>CHAPITRE 1 REVUE DE LITTÉRATURE .....</b>	<b>7</b>
1.1 Éoliennes : technologie, opération et cycle de vie .....	7
1.1.1 Opération des éoliennes .....	8
1.1.2 Le système SCADA .....	13
1.2 Processus d'analyse PHM : détection, diagnostic et pronostic .....	16
1.3 L'autoencodeur variationnel, un réseau de neurones à variables latentes .....	21
1.3.1 Considérations sur les réseaux de neurones : définition, portée, implémentation et mises en garde .....	21
1.3.2 L'autoencodeur variationnel .....	24
1.3.3 Implémentations semi-supervisées et supervisées du modèle VAE .....	29
1.4 Lacunes et opportunités dans l'analyse PHM des éoliennes avec des données SCADA et des modèles d'IA .....	32
<b>CHAPITRE 2 OBJECTIFS ET MÉTHODOLOGIE .....</b>	<b>35</b>
2.1 Objectifs .....	35
2.1.1 Mise en contexte des publications scientifiques .....	37
2.1.2 Retombées escomptées de la recherche .....	37
2.2 Méthodologie .....	38
2.2.1 Hypothèses et portée de la recherche .....	38
2.2.2 Base de données SCADA .....	40
2.2.3 Préparation de la base de données normalisée et étiquetée .....	41
2.2.4 Implémentation numérique du modèle VAEC .....	45
<b>CHAPITRE 3 EARLY DETECTION AND DIAGNOSIS OF WIND TURBINE ABNORMAL CONDITIONS USING AN INTERPRETABLE SUPERVISED VARIATIONAL AUTOENCODER MODE .....</b>	<b>47</b>
3.1 Introduction .....	48
3.1.1 Related Works .....	49
3.1.1.1 Detection of Wind Turbine Abnormal Conditions Using the VAE Model .....	49
3.1.1.2 Diagnosis of Wind Turbine Abnormal Conditions Using the VAE Model .....	50
3.1.1.3 VAE Model as a Visualization Tool .....	51
3.1.2 Main Contributions .....	52
3.1.3 Paper Organization .....	52
3.2 SCADA Database .....	53
3.3 Background .....	56
3.3.1 Variational Autoencoder .....	57

3.3.2	VAE Latent Space for a Multiple-Condition Database .....	59
3.3.3	Semi-Supervised and Supervised Variational Autoencoder .....	60
3.4	Proposed Condition Monitoring Approach .....	61
3.4.1	VAEC Model .....	61
3.4.2	Proposed Health Indicator, Detection, and Diagnosis .....	64
3.4.3	Visualization Tool .....	66
3.5	Methodology .....	66
3.5.1	Database Pre-Processing .....	67
3.5.2	Data Labelling, Balancing, and Partitioning .....	68
3.5.3	VAEC Model : Architecture and Training .....	70
3.6	Results and Discussion .....	70
3.6.1	Reference VAEC Model .....	71
3.6.2	Case Studies .....	73
3.6.2.1	Case Study I : Main Bearing Degradation .....	73
3.6.2.2	Case Study II : Impact of a Cold Wave .....	75
3.7	Summary and Conclusions .....	77

<b>CHAPITRE 4</b>	<b>SYSTEM CONDITION MONITORING BASED ON A STANDARDIZED LATENT SPACE AND THE NATAF TRANSFORM .....</b>	<b>81</b>
4.1	Introduction .....	82
4.2	Problem formulation .....	84
4.2.1	Latent variable models .....	84
4.2.2	Latent variable model for fault detection .....	85
4.2.3	Limitations of the latent manifold for fault detection .....	87
4.2.4	Toward an enhanced latent manifold for fault detection .....	90
4.3	Nataf Isoprobabilistic Transform .....	90
4.3.1	Estimation of the Nataf correlation coefficients .....	92
4.4	Proposed Condition Monitoring Approach .....	95
4.4.1	Database definition and latent space representation .....	95
4.4.2	Standard Nataf space representation .....	97
4.4.3	Health index $I_M$ for outlier detection .....	100
4.4.4	Health index $I_N$ for out-of-distribution detection .....	101
4.4.5	Online condition monitoring .....	103
4.4.6	Performance of the condition monitoring approach .....	103
4.5	Case Study I : Engine Degradation from C-MAPSS database .....	104
4.5.1	The C-MAPSS FD001 dataset .....	104
4.5.2	Latent space projection .....	106
4.5.3	Standard Nataf space and detection criteria .....	107
4.5.4	Early detection of abnormal conditions .....	110
4.6	Case Study II : Wind Turbine Condition Monitoring .....	111
4.6.1	Wind turbine SCADA database .....	111
4.6.2	VAEC model architecture and training .....	115
4.6.3	Suitable model hyperparameters and Nataf transform .....	115

4.6.4	Detection thresholds .....	116
4.6.5	Condition monitoring of a wind turbine impacted by multiple abnormal conditions .....	118
4.6.6	Comparative analysis of the performance for detecting main bearing overtemperature .....	123
4.7	Summary and Discussion .....	125
4.8	Conclusion .....	127
<b>CHAPITRE 5</b>	<b>REMAINING USEFUL LIFE ESTIMATION BASED ON VARIATIONAL AUTOENCODER LATENT SPACE REPRESENTATION: APPLICATION TO WIND TURBINES</b> .....	129
5.1	Introduction .....	129
5.2	Latent Space Representation of Complex Systems .....	132
5.2.1	Latent Variable Models .....	132
5.2.2	Latent Space Representation of Systems Operating at Multiple Conditions .....	133
5.2.3	System Degradation as a Trajectory in the Latent Space .....	134
5.3	A general framework for prognosis based on the latent space representation .....	135
5.3.1	The PHM Analysis .....	136
5.3.2	Latent Space Trajectory Predictor Using Taylor Expansion .....	136
5.3.3	Considerations of the End of Life Criteria .....	138
5.3.4	RUL Estimation .....	140
5.4	Wind Turbine Prognosis Based on the Latent Space Representation .....	142
5.4.1	Latent Space Representation of Wind Turbines .....	143
5.4.2	Characterizing of WT EOL in the Latent Space .....	146
5.4.3	Demonstration With Synthetic Trajectories .....	147
5.4.3.1	Linear Trajectory .....	147
5.4.3.2	A Curvilinear Trajectory .....	149
5.4.4	Prognosis for a Degraded Wind Turbine Main Bearing .....	151
5.5	Conclusion and Prospects .....	154
<b>CHAPITRE 6</b>	<b>SOMMAIRE ET CONTRIBUTIONS DES ARTICLES</b> .....	157
6.1	Portée et hypothèses de la recherche .....	157
6.2	L'espace latent du VAEC comme un outil d'analyse et de visualisation .....	159
6.3	Contributions des articles par question de recherche .....	161
<b>CONCLUSION GÉNÉRALE</b> .....	165	
<b>RECOMMANDATIONS</b> .....	169	
8.1	Recommandations de recherche dans la continuité de cette thèse .....	169
8.1.1	Modèles non supervisés et semi-supervisés .....	169
8.1.2	Interprétabilité et explicabilité de l'intelligence artificielle .....	170
8.1.3	Détection de nouvelles classes de données et vérification de l'adéquation .....	171
8.1.4	Espace latent à zones contraintes selon les conditions d'opération .....	172

8.1.5	Perfectionnement de la modélisation du pronostic .....	173
8.2	Recommandations de recherche au-delà de la portée de cette thèse .....	174
8.2.1	Apprentissage par transfert .....	174
8.2.2	Réseaux de neurones en graphes .....	176
8.2.3	Modèles d'intelligence artificielle multimodaux .....	177
8.3	Recommandations pour le transfert technologique .....	178
8.4	Conclusion des recommandations .....	180
<b>ANNEXE I</b>	<b>ARTICLES DE CONFÉRENCE, ARTICLES DE VULGARISATION SCIENTIFIQUE ET PRÉSENTATIONS ORALES .....</b>	<b>181</b>
<b>BIBLIOGRAPHIE</b> .....	<b>185</b>	

## LISTE DES TABLEAUX

	Page	
Tableau 1.1	Conditions d'opération et modes de dégradation pour les composants critiques des éoliennes .....	10
Tableau 1.2	Études statistiques sur les modes de dégradation des éoliennes .....	12
Tableau 1.3	Implémentations semi-supervisées et supervisées du modèle VAE .....	31
Tableau 2.1	Identification des publications issues du doctorat .....	37
Tableau 2.2	Identification des bases de données SCADA .....	40
Tableau 2.3	Mesures SCADA utilisées comme descripteurs .....	42
Tableau 2.4	Conditions d'intérêt pour les éoliennes .....	43
Tableau 3.1	Conditions d'opération analysées pour les éoliennes .....	53
Tableau 3.2	Identification des mesures SCADA utilisées comme descripteurs .....	55
Tableau 4.1	Quadrature de Gauss-Hermite d'ordre 7 .....	95
Tableau 4.2	Conditions anormales d'opération en lien avec la température .....	112
Tableau 4.3	Identification des mesures SCADA utilisées comme descripteurs .....	113
Tableau 4.4	Approches de détection pour le roulement principal des éoliennes .....	124
Tableau 5.1	Courbes de transition de l'état de santé dans l'espace latent .....	139
Tableau 5.2	Identification des mesures SCADA utilisées comme descripteurs .....	144
Tableau 5.3	Base de données étiquetée .....	145
Tableau 5.4	Influence de la fenêtre temporelle de régularisation .....	153
Tableau 6.1	Contributions de l'article 1 .....	162
Tableau 6.2	Contributions de l'article 2 .....	163
Tableau 6.3	Contributions de l'article 3 .....	163
Tableau 8.1	Synthèse des recommandations pour le transfert technologique .....	179



## LISTE DES FIGURES

	Page
Figure 0.1	Évolution du coût actualisé moyen de l'énergie éolienne de 2020 à 2050 . 2
Figure 1.1	Courbes de coefficient de puissance pour différents types d'éolienne ..... 8
Figure 1.2	Éoliennes à l'axe horizontal à trois pales ..... 9
Figure 1.3	Composants d'une éolienne à l'axe horizontal ..... 9
Figure 1.4	Analyse de criticité des composants d'éoliennes ..... 11
Figure 1.5	Courbe de puissance typique d'une éolienne avec contrôle par angle de calage variable ..... 14
Figure 1.6	Processus d'analyse PHM ..... 16
Figure 1.7	Estimation de la vie utile restante ..... 19
Figure 1.8	Représentation schématique d'un réseau de neurones profond ..... 22
Figure 1.9	Applications des modèles à variables latentes ..... 25
Figure 1.10	Représentation schématique des modèles de l'autoencodeur et de l'autoencodeur variationnel ..... 26
Figure 1.11	Positionnement du modèle VAEC dans le domaine de l'IA ..... 27
Figure 1.12	Représentation schématique du modèle de l'autoencodeur variationnel associé à un classificateur ..... 31
Figure 2.1	Identification des questions de recherche dans le processus PHM ..... 36
Figure 2.2	Procédure pour la définition des ensembles de données par condition ... 44
Figure 3.1	Distribution des ensembles de données d'intérêt ..... 56
Figure 3.2	Représentation schématique du modèle de l'autoencodeur variationnel .. 57
Figure 3.3	Projection de la base de données MNIST dans l'espace latent de l'autoencodeur variationnel ..... 60
Figure 3.4	Représentation schématique du modèle de l'autoencodeur variationnel associé à un classificateur ..... 62

Figure 3.5	Projection de la base de données MNIST dans l'espace latent de l'autoencodeur variationnel associé à un classificateur .....	63
Figure 3.6	Représentation schématique de l'approche proposée .....	67
Figure 3.7	Procédure pour la définition de l'ensemble de données pour la condition de surchauffe de la boîte de vitesses .....	69
Figure 3.8	Projection des conditions d'opération d'éoliennes dans l'espace latent de l'autoencodeur variationnel .....	71
Figure 3.9	Projection des conditions d'opération d'éoliennes dans l'espace latent de l'autoencodeur variationnel associé à un classificateur et matrice de confusion du classificateur .....	72
Figure 3.10	Outil de visualisation pour le cas d'étude I .....	74
Figure 3.11	Détection et diagnostic pour l'étude de cas I .....	75
Figure 3.12	Outil de visualisation pour le cas d'étude II .....	76
Figure 3.13	Détection et diagnostic pour l'étude de cas II .....	77
Figure 4.1	Applications des modèles à variables latentes .....	86
Figure 4.2	Espace latent 2-D pour une base de données à conditions multiples .....	89
Figure 4.3	Projection de l'espace latent dans l'espace standard de Nataf par la transformée de Nataf .....	91
Figure 4.4	Schéma de l'approche proposée pour la surveillance de l'état de santé des systèmes à conditions d'opération multiples .....	96
Figure 4.5	Illustration d'un espace standard de Nataf 2-D projetant un ensemble de données à conditions multiples .....	98
Figure 4.6	Projection dans l'espace standard de Nataf de jeux de données représentant des conditions saine et dégradée .....	99
Figure 4.7	Estimation de $I_N$ à partir de la densité de probabilité de $d(\mathbf{s})$ .....	101
Figure 4.8	Schéma simplifié du moteur turbofan de la C-MAPSS de la NASA .....	105
Figure 4.9	RUL cible et RUL prédite avec le modèle LSTM-VAE-Regression .....	106
Figure 4.10	Représentation dans l'espace latent des données de C-MAPSS FD001 ..	107

Figure 4.11	Projection de la condition saine dans l'espace standard de Nataf .....	108
Figure 4.12	Distribution de la métrique $d$ dans l'espace standard de Nataf .....	108
Figure 4.13	Distribution statistique des indicateurs de l'état de santé estimés à partir des données d'entraînement en condition saine .....	109
Figure 4.14	Indicateurs de santé $I_M$ , $I_N$ et l'alarme pour deux moteurs de la base de données C-MAPSS FD001 .....	109
Figure 4.15	Comparaison entre l'instant d'initiation de la dégradation et les instants de détection par les indicateurs de santé $I_M$ et $I_N$ .....	110
Figure 4.16	Distribution des ensembles de données dans l'espace physique .....	114
Figure 4.17	Espace latent et espace standard de Nataf pour des instances d'entraînement indépendantes .....	117
Figure 4.18	Distribution statistique des indicateurs de l'état de santé estimés sur une éolienne saine .....	118
Figure 4.19	Estimation des indicateurs de l'état de santé pour une éolienne saine et une éolienne dégradée .....	119
Figure 4.20	Chronologie des événements et des alarmes dans l'étude de cas .....	121
Figure 4.21	Estimation de l'indicateur de l'état de santé $I_N$ .....	122
Figure 4.22	Projection de l'étude de cas de surchauffe du roulement principal .....	123
Figure 5.1	Représentation d'un système complexe dans un espace latent 2-D .....	134
Figure 5.2	Analyse PHM basée sur la projection dans l'espace latent .....	137
Figure 5.3	Prédiction de trajectoire étant donné la position initiale $\mathbf{z}(t_0)$ .....	138
Figure 5.4	Échantillons de trajectoires dans l'espace latent de la dégradation jusqu'à la fin de vie .....	141
Figure 5.5	Procédure pour la définition des ensembles de données par condition à partir des données et des alarmes du système SCADA .....	145
Figure 5.6	Projection de la base de données des éoliennes dans l'espace latent .....	146
Figure 5.7	Clusters et courbes de dégradation dans un espace latent 2-D .....	147
Figure 5.8	Trajectoire de dégradation linéaire .....	148

Figure 5.9	Estimation de la RUL pour la trajectoire linéaire .....	149
Figure 5.10	Trajectoire de dégradation curviligne .....	150
Figure 5.11	Estimation de la RUL pour la trajectoire curviligne .....	150
Figure 5.12	Projection dans l'espace latent des points de données SCADA .....	151
Figure 5.13	Fonction de pondération pour la régression polynomiale .....	152
Figure 5.14	Effet de la régularisation par moyenne glissante et de la régression polynomiale avec pondération .....	153
Figure 5.15	Estimation de la RUL pour éolienne avec roulement principal dégradé .	154
Figure 6.1	Vue d'ensemble de la production scientifique .....	157
Figure 8.1	Approche de classification semi-supervisée avec le VAE convolutionnel	170
Figure 8.2	Vérification de l'adéquation à partir de l'erreur de reconstruction .....	172
Figure 8.3	Partition de l'espace latent par conditions d'opération .....	173
Figure 8.4	Parc éolien de Gros Morne .....	175
Figure 8.5	Indicateurs de dégradation pour le Parc éolien de Gros Morne .....	176

## **LISTE DES ALGORITHMES**

	Page
Algorithme 4.1	Évaluation du coefficient de corrélation fictif de Nataf .....
Algorithme 5.1	Estimation de la valeur moyenne de la RUL .....
Algorithme 5.2	Estimation de la pdf de la RUL .....



## LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

AE	Autoencodeur ( <i>Autoencoder</i> )
IA	Intelligence artificielle ( <i>Artificial Intelligence</i> )
cdf	Fonction de distribution cumulative ( <i>Cumulative Distribution Function</i> )
CM	Surveillance de l'état de santé ( <i>Condition Monitoring</i> )
C-MAPSS	<i>Commercial Modular Aero-Propulsion System Simulation</i>
DNN	Réseau de neurones profond ( <i>Deep Neural Network</i> )
EOL	Fin de vie utile ( <i>End of Useful Life</i> )
EWMA	Moyenne glissante exponentiellement pondérée ( <i>Exponentially Weighted Moving Average</i> )
HI	Indicateur de l'état de santé ( <i>Health Index</i> )
LCOE	Coût actualisé de l'énergie ( <i>Levelized Cost of Energy</i> )
LVM	Modèle à variables latentes ( <i>Latent Variable Model</i> )
NT	Transformation de Nataf ( <i>Nataf Transform</i> )
O&M	Opération et maintenance ( <i>Operation and Maintenance</i> )
PHM	Pronostic et gestion de l'état de santé ( <i>Prognosis and Health Management</i> )
pdf	Fonction de densité de probabilité ( <i>Probability density function</i> )
RUL	Vie utile restante ( <i>Remaining Useful Life</i> )
SCADA	Système de contrôle et d'acquisition de données ( <i>Supervisory Control and Data Acquisition</i> )
VAE	Autoencodeur variationnel ( <i>Variational Autoencoder</i> )
VAEC	VAE intégré à classificateur ( <i>VAE Embedded with Classificator</i> )
WT	Éolienne ( <i>Wind Turbine</i> )



## LISTE DES SYMBOLES ET UNITÉS DE MESURE

### Variables opérationnelles des éoliennes

$V_{in}$	Vitesse de vent de démarrage
$V_{out}$	Vitesse de vent de coupure
$V_n$	Vitesse de vent nominale d'opération
$P_n$	Puissance active nominale

### Espaces de représentation

$t, t_k$	Instant, instant dans du temps discréétisé
$x_i, z_i, s_i$	Coordonnées de données de l'espace physique, de l'espace latent et de l'espace standard de Nataf
$\mathbf{x}, \mathbf{z}, \mathbf{s}$	Points de données de l'espace physique, de l'espace latent et de l'espace standard de Nataf, respectivement
$\mathbf{x}_\tau, \mathbf{z}_\tau, \mathbf{s}_\tau$	Ensembles de données couvrant la période $\tau$ de points dans l'espace physique, latent et de Nataf, respectivement
$X_i, Z_i, S_i$	Variables aléatoires décrivant la distribution des coordonnées dans l'espace physique, latent et de Nataf, respectivement
$\mathbf{X}, \mathbf{Z}, \mathbf{U}, \mathbf{S}$	Vecteurs aléatoires décrivant la distribution des points dans l'espace physique, latent, intermédiaire de Nataf et de Nataf, respectivement
$N_X, N, N_C$	Dimensions de l'espace physique, de l'espace latent et de l'espace de classification, respectivement
$p(\mathbf{x})$	Distribution des données
$\mathbb{R}, \mathbb{X}, \mathbb{S}_{healthy}$	Jeux de données
$\mathbf{S}_{HY}, \mathbf{S}_\tau$	Vecteurs aléatoires décrivant la distribution des ensembles de données dans l'espace standard de Nataf
$F_i(z_i)$	cdf correspondant à la variable aléatoire $Z_i$

### Modèles à variables latentes

$\tilde{\mathbf{x}}$	Approximation de $\mathbf{x}$
$\mathcal{L}, \mathcal{L}_{RE}, \mathcal{L}_{KL}, \mathcal{L}_{CL}$	Fonction coût et ses composants
$\beta_{cl}, \beta_{kl}$	Coefficients de la fonction coût
$f_\phi, g_\theta$	Fonctions paramétriques du VAE
$g_\gamma$	Réseau de neurones classificateur du VAEC
$\hat{\mathbf{y}}$	Sortie Softmax du classificateur du VAEC

### Transformée de Nataf

$\mathbf{R}_Z, r_{Zij}$	Matrice de corrélation et coefficients de corrélation décrivant la variable de l'espace latent
$\mathbf{R}_U, r_{Uij}$	Matrice de corrélation fictive de Nataf et coefficients de corrélation
$\mathbf{L}$	Décomposition de Cholesky de la matrice de corrélation
$\mathcal{T}, \mathcal{T}_1, \mathcal{T}_2$	Transformée de Nataf et ses transformées intermédiaires
$D, D_\tau, D_{HY}$	Variables aléatoires décrivant la norme des points des ensembles de données projetés dans l'espace standard de Nataf

### Surveillance de l'état de santé

$I_M, I_N$	Indices de l'état de santé définis dans l'espace standard de Nataf
$DT_M, DT_N$	Seuils de détection
$R^2$	Coefficient de détermination
$\tau, \Delta_{lag}$	Période de temps, temps de décalage ( <i>lag</i> )

### Distributions de probabilité

$\Phi$	cdf de la distribution normale $\mathcal{N}(0, 1)$
$\varphi_N$	cdf jointe de la normale multivariée $\mathcal{N}(\mathbf{0}, \mathbf{1})$
$P_x$	Percentile $x$ d'une distribution
$\chi_N, f_{\chi_N}, F_{\chi_N}$	Distribution $\chi$ avec $N$ degrés de liberté et les respectives pdf et cdf

## INTRODUCTION

La transition énergétique est incontournable pour limiter le changement climatique et ses conséquences. En effet, à l'échelle mondiale, la production et la consommation de l'énergie correspondent à la plus grosse source d'émissions des gaz à effet de serre, étant responsables de 75% du total des émissions selon l'Agence Internationale de l'Énergie (Masson-Delmotte *et al.*, 2018; IEA, 2023, 2021; DNV, 2023).

Les éoliennes constituent une solution technologique privilégiée pour la décarbonisation de la production de l'électricité. De nombreux scénarios préconisent l'augmentation significative de la puissance éolienne installée dans le monde au cours des prochaines décennies. La « Feuille de route pour le secteur énergétique mondial » de l'IEA prévoit que la capacité installée pour les sources éolienne et solaire confondues devra quadrupler entre 2020 et 2030 (Bouckaert *et al.*, 2021). Dans la même direction, la « Prévision de transition énergétique jusqu'en 2050 » (DNV, 2023) estime que la puissance éolienne installée mondiale va être multipliée par un facteur 8 entre 2022 et 2050. Au Québec, le Plan d'action 2035 de l'Hydro-Québec prévoit de tripler la puissance éolienne installée dans la province entre 2023 et 2035 (Hydro-Québec, 2023). Le cadre pour atteindre cette cible est posé par la nouvelle « Stratégie de développement éolien » de l'Hydro-Québec (Hydro-Québec, 2024) et par le Projet de loi n° 69, « Loi assurant la gouvernance responsable des ressources énergétiques et modifiant diverses dispositions législatives » (Assemblée Nationale du Québec, 2024).

Les scénarios d'augmentation du taux de pénétration de l'énergie éolienne à l'échelle globale sont fondés sur la prémissse de continuité des tendances de baisse du coût actualisé de l'énergie (LCOE, *Levelized Cost of Energy*) éolienne, comme indiqué dans la figure 0.1. Deux facteurs clés de cette tendance sont les économies à partir de l'amélioration du facteur de capacité (associé au taux de disponibilité) et les économies par la réduction des dépenses en lien avec les interventions pour l'opération et la maintenance des parcs éoliens (Bouckaert *et al.*, 2021;

DNV, 2020). Selon les prévisions par DNV (2020), la réduction des coûts d’O&M constitue une fraction significative de la baisse prévue du LCOE entre 2020 et 2050. Le ratio réduction coûts O&M sur réduction totale du LCOE est de 18% pour les éoliennes sur terre et monte jusqu’à 36% pour les éoliennes en mer (DNV, 2020; DNV-GL, 2021; DNV, 2022a, 2023).

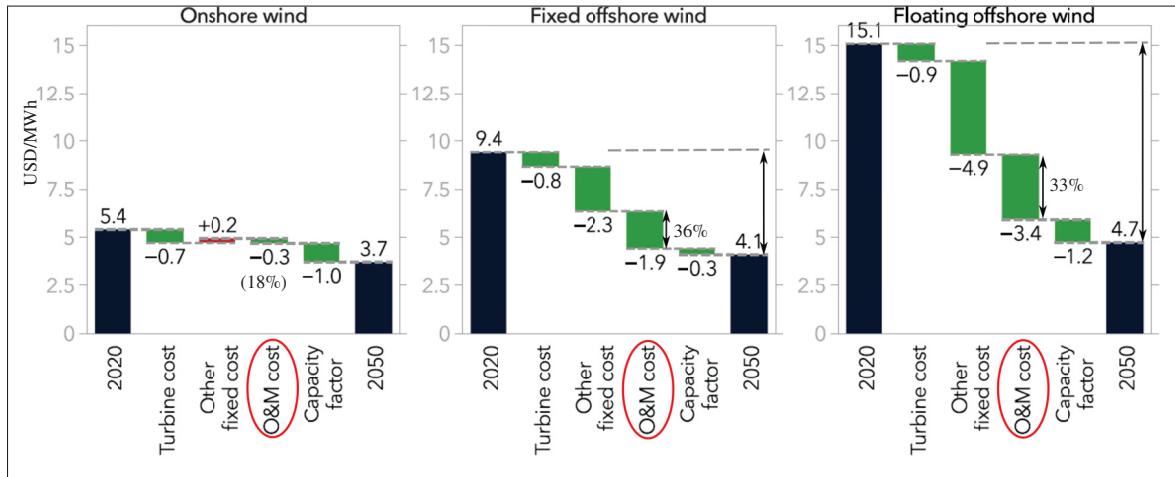


Figure 0.1 Évolution des composantes du coût actualisé moyen [USD/MWh] mondial de l’énergie éolienne entre 2020 et 2050  
Tirée de DNV (2020, p. 109)

D’autres facteurs importants pour le succès des projets de parcs éoliens sont l’acceptabilité des populations locales, les choix politiques des gouvernements et l’engagement des investisseurs. Les décisions par ces acteurs sont influencées par la perception des éoliennes comme une solution appropriée pour faire face au changement climatique, ce qui renforce l’importance de rendre les éoliennes encore plus fiables, disponibles et rentables (Bouchard Bastien, Roy Malo & Grenier, 2024; DNV, 2023).

D’après Keller, Sheng, Guo, Gould & Greco (2021), « l’amélioration de la disponibilité des éoliennes grâce à l’analyse des données » [traduction] figure parmi les principaux efforts pour soutenir le secteur éolien. Cela motive une intense activité de recherche, particulièrement dans le domaine du PHM. Le processus d’analyse PHM comprend plusieurs étapes, notamment la

détection, le diagnostic et le pronostic. Les modèles résultant de ces analyses apportent des informations pour guider la prise de décisions concernant l’O&M des actifs.

En particulier, le pronostic permet la mise en place d’une stratégie de maintenance dite prédictive (ou prévisionnelle). Il s’agit d’une stratégie optimale pour la planification en amont des interventions d’O&M basée sur la prédiction de l’évolution de l’état d’un système ou composant (Gouriveau, Medjaher & Zerhouni, 2017). Cela apporte plusieurs gains par rapport aux stratégies de maintenance curative et préventive (ou systématique). En effet, la maintenance prédictive est associée (i) à la réduction de la fréquence et la sévérité des dégradations et défaillances ; (ii) à l’augmentation du taux de disponibilité ; (iii) à l’augmentation du taux de fiabilité et (iv) à la réduction des coûts d’O&M (Zio, 2024; Chebel-Morello, Nicod & Varnier, 2017a; Zio, 2024). L’intérêt stratégique des analyses PHM motive des investissements considérables sur les recherches dans ce domaine.

Les étapes du processus PHM pour les éoliennes ont atteint différents niveaux de maturité. Alors que les modèles de détection et de diagnostic sont plutôt bien développés et amplement utilisés chez les opérateurs des parcs éoliens, le pronostic pose encore des défis scientifiques et techniques (Keller *et al.*, 2021; Veers *et al.*, 2022). D’abord, de nombreux modèles de pronostic proposés dans la littérature ne sont pas applicables aux éoliennes en opération à cause de la nature des données disponibles. D’un côté, plusieurs modèles sont construits à partir de données inaccessibles pour la plupart des éoliennes telles que des mesures de vibration (Elforjani, 2020) ou des résultats d’analyses des lubrifiants (Yucesan & Viana, 2022, 2020b), etc. De l’autre côté, certains travaux utilisent encore des données fictives ou des données générées par des modèles de simulation, ne tenant pas compte des particularités des données opérationnelles.

Le système de contrôle et d’acquisition de données SCADA est présent par défaut dans les éoliennes modernes. Il est donc une source de données privilégiée pour bâtir des analyses PHM dédiées aux parcs éoliens. Les mesures SCADA définissent un espace de description physique à

haute dimension avec des relations complexes entre les mesures. La modélisation basée sur la physique n'est en général pas adaptée aux approches de PHM appliquée aux éoliennes à cause du manque d'accès aux spécifications mécaniques et de dimensionnement de ces systèmes.

Les modèles d'IA se popularisent dans le domaine du PHM appliquée aux éoliennes grâce à leurs capacités à modéliser des comportements non linéaires et aussi des relations subtiles entre les multiples variables SCADA. Même si certains résultats sont encourageants, l'aspect boîte noire des modèles d'IA utilisés limite leur implémentation en industrie. Le manque d'interprétabilité freine la confiance sur les résultats et, a fortiori, le transfert technologique (Zhao *et al.*, 2021b).

Dans ce contexte, cette thèse est motivée par l'implémentation du processus d'analyse PHM pour les éoliennes à partir de données du système SCADA en utilisant un modèle d'IA interprétable. La recherche se concentre sur des modèles explorant les capacités de l'IA tout en étant interprétables, ce qui remplit le besoin pour des modèles avancés pour appuyer la prise de décisions et l'optimisation des interventions d'O&M.

Les recherches comparatives des modèles d'IA ont amené au choix des modèles d'apprentissage profond à variables latentes (LVM, *Latent Variable Model*) à l'instar du modèle VAE. Un LVM supervisé permet de compresser les informations provenant des données SCADA dans un espace latent 2D représentatif de l'état de santé des éoliennes. Les articles scientifiques constituant cette thèse englobent des analyses PHM à partir de la projection des données SCADA sur espace latent. Des études de cas réelles sont utilisées pour démontrer que l'approche proposée apporte des gains en performance par rapport aux méthodes classiques de régression, ainsi que l'usage de l'espace latent comme un outil de visualisation qui confère de l'interprétabilité au modèle.

Cette thèse se veut une contribution au secteur éolien par le développement d'analyses permettant l'optimisation des performances opérationnelles des éoliennes. Cette optimisation comprend deux critères principaux, à savoir l'augmentation du taux de disponibilité des éoliennes et la

réduction du LCOE de l'énergie éolienne (Yang, Tavner, Crabtree, Feng & Qiu, 2014; DNV, 2023). En ultime instance, l'amélioration des performances des parcs éoliens contribue à consolider l'expansion du secteur éolien et donc la transition énergétique.

Cette thèse est structurée comme suit :

Introduction Mise en contexte de la recherche appliquée, présentation des lacunes de l'état de l'art et des motivations de la recherche ;

Chapitre 1 Revue de littérature : établit le cadre théorique de la recherche et dresse un portrait concis de l'état de l'art de la recherche dans le domaine du PHM appliqué aux éoliennes ;

Chapitre 2 Objectifs et méthodologie : présente les objectifs spécifiques de la recherche sous forme de questions de recherche ; présente les hypothèses de travail et les méthodes mises en place pour notre étude ;

Chapitre 3 Reproduction de l'article 1, (Oliveira-Filho, Zemouri, Cambron & Tahan, 2023)<sup>1</sup> :

Détection et diagnostic des conditions anormales des éoliennes à partir d'un modèle d'autoencodeur variationnel supervisé interprétable

Ce premier article introduit le LVM utilisé pour projeter les données SCADA dans un espace latent 2D. De plus, un indicateur de santé est défini à partir de l'espace latent pour la détection d'anomalies. L'indicateur est basé sur la distance entre les points projetés et la distribution saine dans l'espace latent. L'article démontre l'usage de l'espace latent comme un outil de visualisation qui apporte de l'interprétabilité à l'approche proposée.

---

<sup>1</sup> Titre original en anglais : *Early Detection and Diagnosis of Wind Turbine Abnormal Conditions Using an Interpretable Supervised Variational Autoencoder Model.*

Chapitre 4 Reproduction de l'article 2, (Oliveira-Filho, Zemouri, Pelletier & Tahan, 2024)<sup>2</sup> :

Surveillance de l'état de santé des systèmes basée sur un espace latent standardisé et la transformation de Nataf

Cette deuxième publication utilise la transformée isoprobabiliste de Nataf pour projeter l'espace latent dans l'espace standardisé de Nataf. Deux indicateurs de santé complémentaires sont définis à partir de cet espace, permettant la détection d'anomalies se manifestant de manières différentes dans cet espace.

Chapitre 5 Reproduction de l'article 3<sup>3</sup> :

Estimation de la durée de vie utile restante à partir de la représentation de l'espace latent avec l'autoencodeur variationnel : Application aux éoliennes

Cet article introduit un modèle pour estimer la vie restante utile à partir de l'espace latent. Le critère de fin de vie est décrit comme une région de cet espace. La projection des données SCADA est associée à une trajectoire dans l'espace latent.

Chapitre 6 Sommaire et contributions des articles : ce chapitre décrit les contributions apportées par les trois articles scientifiques ;

Conclusion générale Vue d'ensemble de la thèse, ses contributions et ses limites ;

Recommandations Liste des recommandations pour recherches futures et le transfert technologique ;

Annexe Présente des articles de conférence, affiche, article de vulgarisation et des présentations orales ayant contribué à la formation du doctorant.

---

<sup>2</sup> Titre original en anglais : *System Condition Monitoring Based on a Standardized Latent Space and the Nataf Transform.*

<sup>3</sup> Titre original en anglais : *Remaining Useful Life Estimation Based on Variational Autoencoder Latent Space Representation : Application to Wind Turbines.*

# CHAPITRE 1

## REVUE DE LITTÉRATURE

Cette revue pose le cadre théorique de la thèse. La section 1.1 décrit les éoliennes, caractérisant leurs modes d'opération et de dégradation. La section 1.2 décrit le processus d'analyse PHM. La section 1.3 passe en revue des modèles d'IA basés sur le VAE. Enfin, la section 1.4 identifie les lacunes et les opportunités de recherche dans le domaine du PHM appliqué aux éoliennes utilisant des données SCADA et des modèles d'IA.

### 1.1 Éoliennes : technologie, opération et cycle de vie

Les éoliennes sont des systèmes de conversion d'énergie qui convertissent l'énergie cinétique du vent en électricité ou, moins souvent, d'autres formes d'énergie. Il convient de noter que différentes dénominations sont retrouvées pour ces systèmes selon la région géographique ou la communauté de recherche. Quelques exemples sont : système de conversion d'énergie éolienne ou, en anglais, *Wind Energy Conversion System* (Li *et al.*, 2020); système éolien ou *Wind Turbine System* (Shah *et al.*, 2021); turbines éoliennes ou *Wind Turbine* (Bošnjaković, Katinić, Santa & Marić, 2022) ; éolienne commerciale ou *Commercial Wind Turbine* (Guo *et al.*, 2023); ou encore aérogénérateur (Multon *et al.*, 2002). Les termes « éolienne » et « *Wind Turbine* » (pour les textes en anglais) ont été retenus pour désigner l'objet d'étude de cette thèse puisque ce sont les plus usuels en Amérique du Nord.

Par ailleurs, plusieurs types d'éoliennes existent, comme illustré dans la figure 1.1. Pour chaque configuration d'éolienne, la courbe de coefficient de puissance  $C_P$  (adimensionnel) versus la vitesse spécifique  $\lambda$  (*Tip Speed Ratio*, aussi adimensionnelle) est fournie. La figure 1.1 montre que les éoliennes à l'axe horizontal munies d'un rotor à trois pâles présentent les plus hautes valeurs de  $C_P$  pour  $\lambda \in [5, 9]$ . C'est une des raisons pour laquelle le secteur de l'énergie éolienne a priorisé cette configuration d'éoliennes depuis quelques décennies.

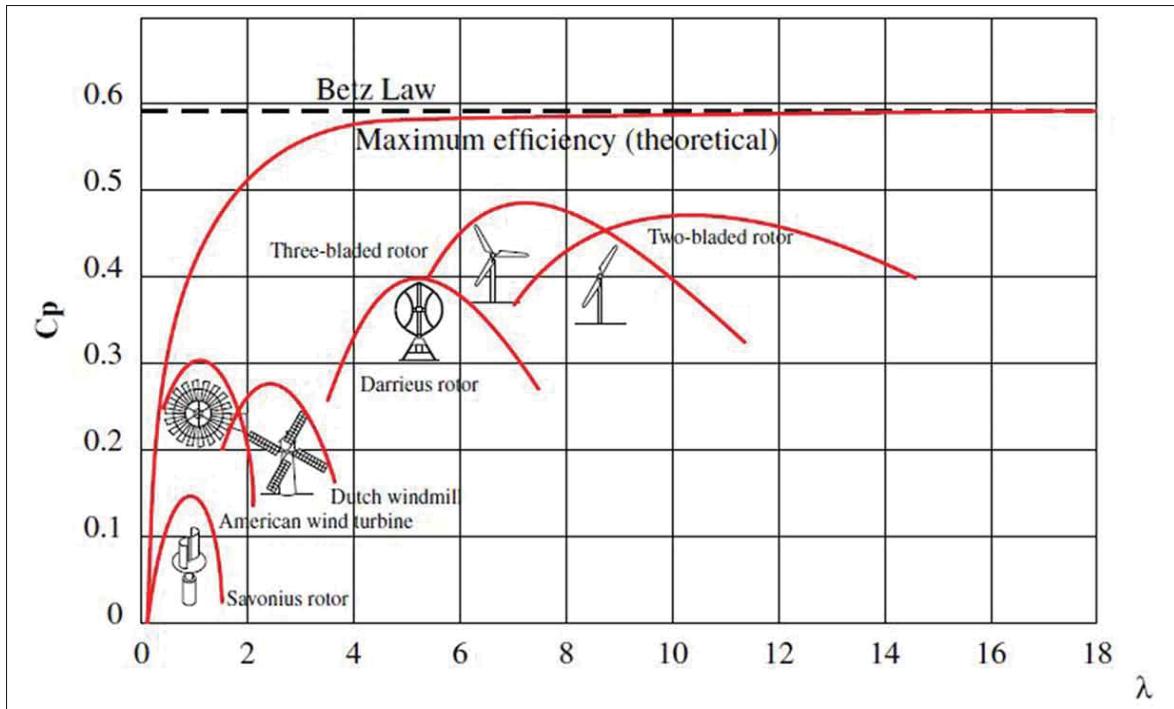


Figure 1.1 Courbes de coefficient de puissance  $C_P$  (adimensionnel) versus la vitesse spécifique  $\lambda$  (adimensionnelle) pour différents types d'éolienne  
Tirée de Pujari *et al.* (2021, p. 2)

Dans cette thèse, les mentions à « éolienne » et « Wind Turbine » réfèrent à une configuration précise, soit des éoliennes à l'axe horizontal munies d'un rotor à trois pales. La figure 1.2 illustre des exemples de telles éoliennes dans des parcs éoliens en opération.

### 1.1.1 Opération des éoliennes

La conversion d'énergie cinétique du vent en énergie électrique comprend les mécanismes suivants : (i) l'entraînement du rotor par les forces aérodynamiques du vent sur les pales ; (ii) transmission du couple du rotor à l'arbre principal qui est soutenu par le roulement principal ; (iii) multiplication de la vitesse de rotation dans la boîte de vitesses ; (iv) enfin, dans le générateur, la rotation rapide de l'induit par rapport au stator (l'inducteur) induit un champ magnétique variable qui, selon la loi de Faraday, crée le courant électrique alternée. La figure 1.3 identifie les composants de la chaîne cinématique d'une éolienne à l'axe horizontal.



Figure 1.2 Éoliennes à l'axe horizontal à trois pales :

- (a) parc éolien Le Nordais, Cap-Chat, QC, Canada
- (b) parc éolien Itarema, Itarema, CE, Brésil et
- (c) parc éolien La Muela, Zaragoza, Espagne

Photos prises par l'auteur

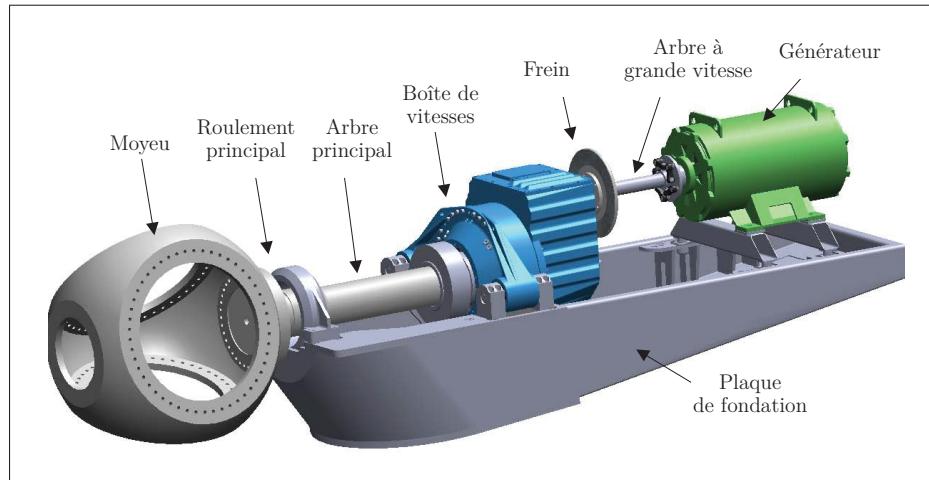


Figure 1.3 Composants d'une éolienne à l'axe horizontal  
Tirée de Oyague (2011, p. 10)

Les éoliennes sont continuellement soumises à des chargements liés à l'opération nominale et aux intempéries. Ces chargements sont pris en compte lors de la conception des éoliennes par les

manufacturiers ainsi que lors de la définition d'un projet de parc éolien. La norme « IEC-61400-1 Systèmes de génération d'énergie éolienne — Exigences de conception » établit des critères pour assurer l'intégrité structurelle des éoliennes. Cette norme fait référence à de nombreuses normes complémentaires auxquelles tout projet d'éolienne doit se conformer.

L'opération nominale des éoliennes soumet ses composants à des chargements complexes. Au cours du temps, ces chargements peuvent amorcer des modes de dégradation spécifiques. Le tableau 1.1 identifie les conditions de chargement sur quatre composants des éoliennes ainsi que les respectifs modes de dégradation.

Tableau 1.1 Résumé des conditions d'opération et des modes de dégradation pour les composants critiques des éoliennes  
Tableau élaboré à partir de Rezamand *et al.* (2020a)

<b>Composant</b>	<b>Conditions de Fonctionnement</b>	<b>Modes de Dégradation</b>
Générateur	Opèrent sous des vitesses de rotation et températures élevées. Certains environnements peuvent être hautement corrosifs.	<i>Flutting</i> à la suite de fuites de courant, panne de l'isolation des enroulements de stator, asymétrie électrique du rotor.
Boîte de vitesses	Opèrent sous des vitesses de rotation et températures élevées. Certains environnements peuvent être hautement corrosifs. Démarrages, arrêts et changements brusques impliquent de hauts niveaux de contrainte.	Endommagement du roulement, endommagement des engrenages, fuite ou contamination de l'huile de lubrification, arbre cassé.
Rotor	En contact direct avec le vent et les intempéries. Pour les éoliennes en mer, l'environnement maritime s'avère particulièrement rude à cause du sel de la mer et les perturbations couplées à l'ancrage de la tour.	Des défaillances du matériau composite des pâles : délamination, défaillance des jointes adhésives, défaillance des fibres ou de la matrice en résine ; collision avec la tour ; incidence d'éclairs.
Roulements	Opèrent sous des vitesses de rotation et températures élevées. Certains environnements peuvent être hautement corrosifs.	Corrosion, écaillage, piqûres et d'autres défauts dans les composants du roulement ; contamination de la lubrification.

L'analyse des modes de dégradation et défaillance des éoliennes est importante à plusieurs égards. En effet, cette caractérisation permet aux manufacturiers de perfectionner la conception des éoliennes et d'apporter des corrections et améliorations dans leurs processus de conception et production. L'émergence des éoliennes à transmission directe (sans boîte de vitesses) en est un exemple (Song *et al.*, 2020). Pour les opérateurs des parcs éoliens, connaître les dégradations les plus fréquentes permet d'optimiser les interventions d'opération en maintenance en priorisant les modes de dégradation les plus critiques. Deux critères sont courants pour caractériser le niveau de criticité d'un composant éolien : le temps d'arrêt à cause des défaillances et la fréquence des défaillances (Kim *et al.*, 2011; Rezamand *et al.*, 2020a). À titre d'exemple de l'analyse des modes de dégradation et défaillance des éoliennes, la figure 1.4 reproduit les statistiques détaillées pour la base de données *Wissenschaftliches Mess-und Evaluierungsprogramm* (WMEP). La base de données de WMEP comprend l'opération de 1500 éoliennes en Allemagne entre 1989 et 2006, avec plus de 15000 cas de défaillances recensés.

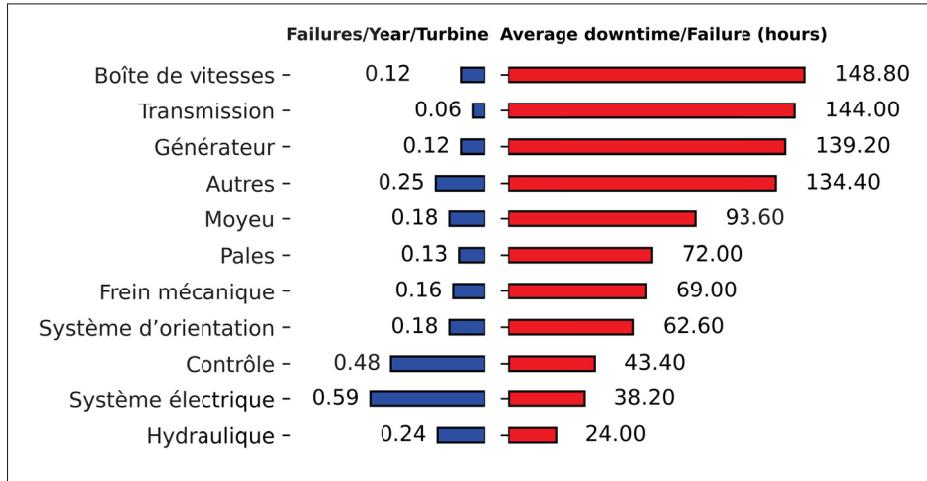


Figure 1.4 Analyse de criticité des composants d'éoliennes pour la base de données WMEP  
Adaptée de Santelo *et al.* (2021, p. 7)

Le tableau 1.2 fournit des statistiques sur les modes de dégradation pour quatre bases de données d'opération des éoliennes. Les composants critiques vis-à-vis de la fréquence des défaillances et du temps d'arrêt moyen par défaillance y sont indiqués.

Tableau 1.2 Études statistiques sur les modes de dégradation des éoliennes  
 Tableau élaboré à partir de Kim *et al.* (2011) et Santelo *et al.* (2021)

<b>Base de données</b>	<b>(a)</b>	<b>(b)</b>	<b>(c) LWK</b>	<b>(d) WMEP</b>
<b>Provenance</b>	Multiple	Suède	Danemark	Allemagne
<b>Nombre de machines</b>	3000+	600+	650+	1500+
<b>Date des données</b>	1997-2008	2000-2004	1993-2006	1989-2006
<b>Défaillances par année par éolienne*</b>	0.12	0.402	1.92	2.51
<b>Temps d'arrêt (mois) par défaillance*</b>	150	130	131.6	69.53
<b>Composant critique — fréq. des défaillances</b>	Système électrique	Système électrique	Système Yaw	Système électrique
<b>Composant critique — temps d'arrêt</b>	Boîte de vitesses	<i>Drive train</i> <sup>†</sup>	Boîte de vitesses	Boîte de vitesses

\* Valeurs moyennes pour tous les modes de dégradation confondus ; <sup>†</sup> *Drive train* : composants reliés au système de rotation tels que les essieux, les roulements et le moyeu des pales.

Le tableau 1.2 permet de conclure que la boîte de vitesses est le composant le plus critique par rapport au temps d'arrêt moyen par occurrence de défaillance. Dans ce sens, Kim *et al.* (2011) soulignent que la boîte de vitesses est le composant qui inquiète le plus les propriétaires et les opérateurs, selon des retours d'expérience recueillis. Cela ressort aussi dans l'ensemble des rapports parus sur le PHM pour les éoliennes. D'ailleurs, la boîte de vitesses est le composant avec le plus grand nombre d'articles publiés (Maldonado-Correa, Martín-Martínez, Artigao & Gómez-Lázaro, 2020). La littérature et les acteurs du secteur de l'énergie éolienne sont consensuels sur l'indication des trois composants les plus critiques d'une éolienne, à savoir la boîte de vitesses, le générateur et le rotor. Au niveau des éléments constitutifs de ces composants, les roulements s'avèrent l'élément le plus critique (Abid, Mouchaweh & Cornez, 2018; Daems *et al.*, 2020; Rezamand *et al.*, 2020a).

La défaillance d'un composant éolien est coûteuse à plusieurs égards. Premièrement, la mise à l'arrêt d'une éolienne suite à des dégradations implique des pertes de production d'énergie et, donc, de revenu. Deuxièmement, la mobilisation de ressources pour la réparation est dispendieuse. Cela d'autant plus que les parcs éoliens peuvent être éloignés et que les interventions in situ soient limitées par des contraintes logistiques et météorologiques. Enfin, une faible fiabilité peut

comporter des coûts pénalisés auprès des assureurs (Chebel-Morello *et al.*, 2017a). En vue de ces considérations et du coût élevé des actifs éoliens, les opérateurs des parcs éoliens mettent en place des stratégies d'opération et de maintenance permettant de soutenir des taux de fiabilité et disponibilité élevés (May, McMillan & Thöns, 2015). En particulier, le domaine du PHM introduit un nouveau paradigme pour l'opération et la maintenance, celui de la maintenance prédictive ou prévisionnelle. Le processus d'analyse PHM est décrit en détail dans la section 1.2.

### **1.1.2 Le système SCADA**

Le système SCADA est embarqué par défaut dans les éoliennes modernes, étant fondamental pour le fonctionnement même de ces systèmes. En effet, le système SCADA ajuste le régime d'opération des éoliennes en fonction des conditions météorologiques et selon les demandes du réseau électrique auquel le parc éolien est raccordé.

Le système SCADA comprend plusieurs capteurs. Les données sont acquises avec des fréquences d'acquisition qui dépendent des capteurs et des configurations d'acquisition. Ensuite, les mesures enregistrées sont concentrées sous forme de séries temporelles avec un pas de temps de 10 minutes, chaque valeur étant la moyenne sur l'intervalle de 10 minutes précédent la mesure. En plus de la valeur moyenne, d'autres statistiques pour les données sur intervalles de 10 minutes peuvent être stockées aussi, par exemple le minimum, le maximum et l'écart-type (Astolfi, Castellani, Lombardi & Terzi, 2021). Cette convention pour le stockage des données SCADA permet de limiter le volume de données tout en préservant l'information nécessaire pour les analyses du suivi de la performance.

Le système SCADA inclut des mesures mécaniques, thermiques et électriques. Quelques exemples sont listés ci-dessous.

- Mesures thermiques : température ambiante [°C], température au boîtier du moteur [°C] pour ajuster l'angle de calage des pâles, température au boîtier de la batterie [°C], température des roulements [°C], température au roulement principal [°C], température de l'huile de

refroidissement de la boîte de vitesses [°C], température sur plusieurs positions autour du générateur [°C], température du système de refroidissement du générateur [°C].

- Mesures électromagnétiques : courant A [A], courant B [A], courant C [A], fréquence [Hz], puissance active [W], différences de potentiel électrique [V].
- Mesures cinématiques : vitesse du vent [m/s], vitesse de rotation du rotor [rpm], vibration de la tour [m/s<sup>2</sup>].
- Mesures géométriques : angles de calage des pales [°], angle d'orientation de la nacelle [°].

Les données SCADA sont utilisées pour suivre l'état des éoliennes en continu. Les mesures SCADA permettent l'analyse de surveillance de la performance (*Performance Monitoring*). Cette analyse est basée sur la courbe de puissance (*Power Curve*), qui est le diagramme de la puissance active [W] en fonction de la vitesse du vent [m/s]. Cette représentation est couramment utilisée en industrie puisqu'elle permet la détection rapide de sous-performances et même le diagnostic de certains types de comportements anormaux. La courbe de puissance typique pour une éolienne avec vitesse de rotation du rotor variable et contrôle par l'angle de calage des pâles (*Pitch-Controlled Variable-Speed Wind Turbine*) est reproduite dans la figure 1.5.

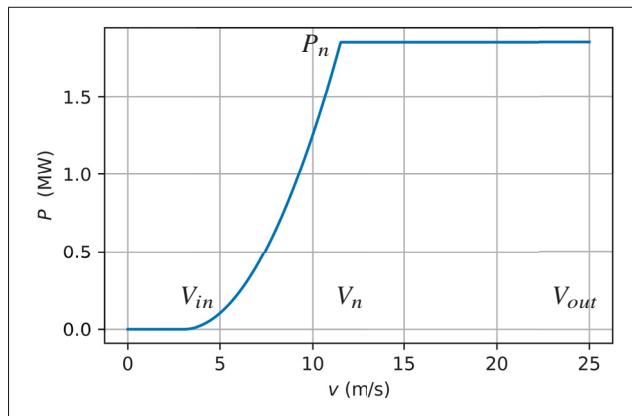


Figure 1.5 Courbe de puissance typique d'une éolienne avec contrôle par angle de calage variable

Le modèle analytique approximative de la puissance  $P$  [W] en fonction de la vitesse du vent  $v$  [ $m \cdot s^{-1}$ ] est donné par l'équation 1.1 :

$$P = \frac{1}{2}\pi R^2 \rho v^3 C_p(\beta, \lambda) I_{[V_{in}, V_n]}(v) + P_n I_{[V_n, V_{out}]}(v) \quad (1.1)$$

où  $P_n$  est la puissance nominale,  $V_{in}$  est la vitesse de démarrage (*Cut-in Speed*),  $V_n$  est la vitesse nominale,  $V_{out}$  est la vitesse d'arrêt (*Cut-out Speed*) et  $I$  est la fonction indicatrice —  $I_{[a,b]}(v) = 1$  si  $v \in [a, b]$ , 0 sinon. Dans la composante pour  $v \in [V_{in}, V_n]$ ,  $R$  [m] est le rayon du rotor,  $\rho$  [ $kg \cdot m^{-3}$ ] est la masse volumique de l'air et  $C_p(\beta, \lambda)$  est le coefficient de puissance aérodynamique du rotor. Ce coefficient est fonction de l'angle de calage des pales  $\beta$  et du ratio  $\lambda$  entre la vitesse relative du vent à l'extrémité du rotor par la vitesse du vent (Astolfi *et al.*, 2021).

En pratique, la courbe de puissance expérimentale d'une éolienne sur un site donné est estimée à partir des séries temporelles de la vitesse du vent et de la puissance active. De nombreuses approches existent pour tracer la courbe de puissance (Wang, Hu, Li, Foley & Srinivasan, 2019b). Le principal intérêt pour établir la courbe de puissance d'une éolienne pour une période d'opération donnée c'est de comparer la courbe expérimentale et la courbe nominale fournie par le manufacturier. Cette analyse peut mettre en évidence des sous-performances, étant une approche consolidée dans l'industrie. La courbe de puissance peut être utilisée aussi pour le diagnostic. En effet, quelques anomalies ont des signatures particulières sur la courbe de puissance. Le givrage des pâles en est un cas classique. Le givrage de pale se traduit par des courbes de puissance déplacées vers le bas par rapport à la courbe de puissance nominale, un motif rapidement identifiable par un analyste expérimenté (Davis, Byrkjedal, Hahmann, Clausen & Žagar, 2016).

Cependant, étant donné que le suivi de la performance classique ne considère que la courbe de puissance, plusieurs autres mesures SCADA sont négligées. En plus, l'évolution de l'état de l'éolienne au cours du temps n'est pas mise en évidence par la courbe de puissance. Pour contourner cela, quelques variations de la surveillance de la performance ont été proposées dans la littérature (Astolfi *et al.*, 2021).

Pour finir, il convient de noter que la littérature distingue deux systèmes d'acquisition des éoliennes, à savoir le système SCADA et le système de surveillance de l'état de santé (*Condition Monitoring System*) (Rezamand *et al.*, 2020a). À l'opposé du SCADA, le système de surveillance de l'état de santé n'est pas installé par défaut dans les éoliennes. Moyennant des investissements, il serait possible d'installer des capteurs dans les éoliennes pour avoir accès à des mesures autres que celles à disposition. Cela n'a pas été envisagé dans le cadre de cette thèse.

## 1.2 Processus d'analyse PHM : détection, diagnostic et pronostic

Cette thèse couvre les multiples étapes du processus d'analyse PHM, c'est pourquoi cette section se penche sur ce cadre d'analyse. La figure 1.6 reproduit le schéma du processus d'analyse PHM proposé dans le livre *Du concept de PHM à la maintenance prédictive 1* (Gouriveau *et al.*, 2017).

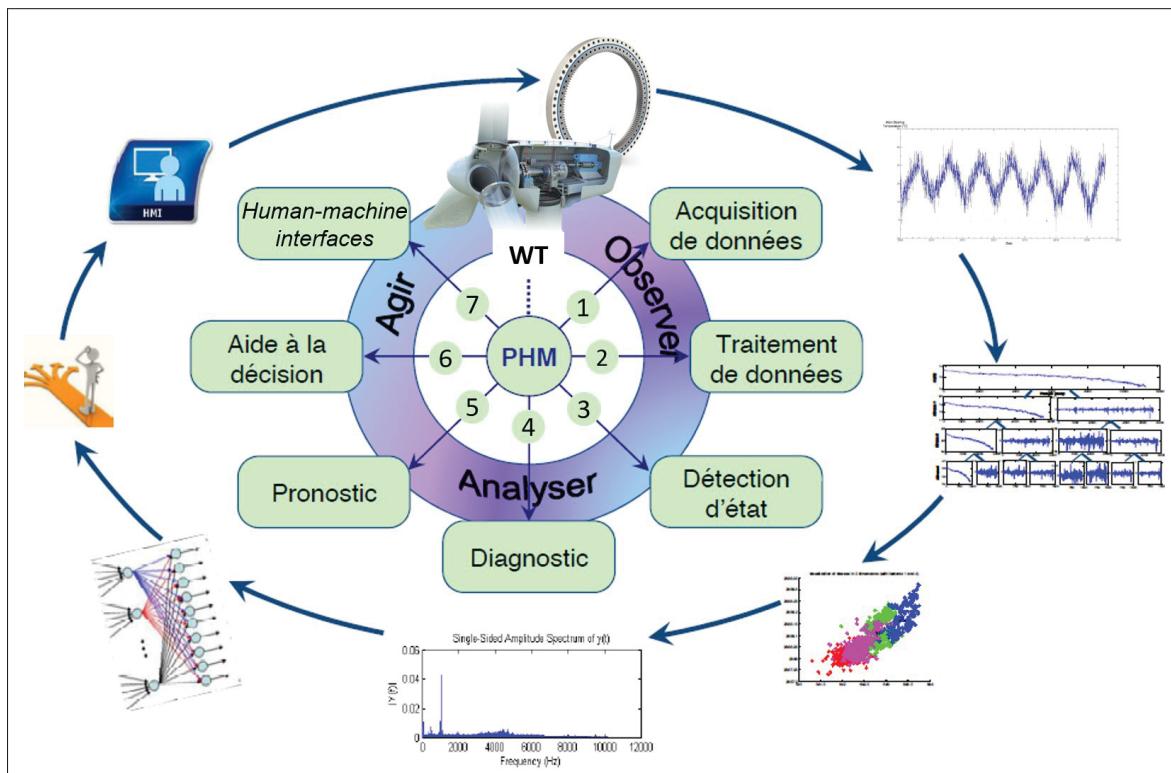


Figure 1.6 Schéma du processus d'analyse PHM  
Adaptée de Gouriveau *et al.* (2017, p. 27)

Gouriveau, Medjaher & Zerhouni (2017) présentent le processus d'analyse du PHM comme une généralisation du cadre d'analyse *Open System Architecture for Condition Based Maintenance* initialement proposé par le groupe MIMOSA (MIMOSA, 2006). Ce cadre a donné matière à la normalisation ISO 13374-2 « *Condition monitoring and diagnosis of machines — data processing, communication and presentation* » et s'est avéré un outil pertinent pour décrire le processus d'analyses PHM. Ce processus comprend les sept étapes suivantes : (1) l'acquisition de données, (2) le traitement des données, (3) la détection de l'état, (4) le diagnostic, (5) le pronostic, (6) l'aide à la décision et (7) la présentation.

Les étapes (1) et (2) — acquisition et traitement des données — permettent de construire une base de données appropriée pour les analyses du processus PHM. Dans (Gouriveau *et al.*, 2017), le traitement des données comprend trois aspects, à savoir : extraction de descripteurs (*features*), réduction/sélection de descripteurs et construction d'indicateurs de santé (HI, *Health Indicators*). Les descripteurs décrivent le système de façon plus appropriée que les données brutes. Les indicateurs de santé sont des fonctions de quelques descripteurs jugés pertinents pour capter l'évolution et représenter le système et son état de santé/intégrité. La réduction ou sélection des descripteurs est nécessaire pour supprimer la redondance, des défauts ou des biais de la base de données (Gouriveau *et al.*, 2017).

À l'étape (3), la détection se fait à partir d'un descripteur qui indique, par un critère spécifique à chaque HI, si le composant analysé est dans un état de fonctionnement normal ou pas. L'intérêt de la détection et du suivi de la condition est de pouvoir détecter les anomalies avant qu'elles ne deviennent sévères ou dangereuses. Cela dit, le temps d'anticipation de la défaillance par la détection est une variable essentielle pour les méthodes de détection. Ce temps doit être suffisamment long pour permettre des actions par l'opérateur du parc éolien. La détection d'une anomalie ou d'une tendance devra déclencher à une action. En pratique, l'idéal est donc que la notification de la détection ait lieu bien avant la défaillance. L'action prise par l'opérateur dépend de la dégradation détectée et du composant critique impacté. Ça pourrait être l'arrêt de la machine, l'ajustement de l'opération à une puissance inférieure à la puissance nominale (*curtailment*), le

déclenchement d'un protocole pour l'inspection, la réalisation d'analyses plus poussées visant le diagnostic et le pronostic (Atamuradov, Medjaher, Dersin, Lamoureux & Zerhouni, 2017).

L'analyse du diagnostic à l'étape (4) vise la caractérisation de l'anomalie détectée. Alors que la détection répond à une question binaire — il y a une anomalie dans l'opération du composant sous analyse ? —, le diagnostic répond à des questions ouvertes : quelle est la source de l'anomalie ? Quel est le niveau de la dégradation ? Quelle est l'action la plus judicieuse à prendre ? Est-ce viable d'établir le régime de *Curtailment* (Atamuradov *et al.*, 2017). La précision du diagnostic dépend donc des informations disponibles. Par exemple, le diagnostic établi à partir de la courbe de puissance uniquement ne sera pas aussi précis et fiable que le diagnostic établi à partir de l'analyse du spectre des vibrations des roulements de la chaîne de transmission.

Le principal objectif de l'étape (5), pronostic, c'est d'évaluer « combien de temps un composant défaillant peut fonctionner en conditions fiables tout en gardant des indicateurs de performance souhaités » (Rezamand *et al.*, 2020a). La présence d'une défaillance n'est pas une prémissse dans la définition du pronostic proposée par (Vichare & Pecht, 2006) : il s'agit d'un « processus de prédiction d'un futur état (de fiabilité) basé sur les conditions actuelles et historiques ». Ces deux sens du pronostic sont repris dans la définition de la norme ISO 13381 (2004) : le pronostic a pour but « d'estimer la durée de fonctionnement avant défaillance d'un système et le risque d'existence ou d'apparition ultérieure d'un ou de plusieurs modes de défaillance ».

En pratique, les analyses du pronostic doivent permettre l'estimation de la RUL du composant analysé, c'est-à-dire le temps restant jusqu'à la fin de la vie utile du composant. Soit  $t_c$  l'instant actuel et  $t_f$  l'instant de défaillance prédit avec le modèle de pronostic tenant compte d'un modèle pour l'état de dégradation et d'un seuil de défaillance. La valeur centrale de la RUL se calcule alors avec l'équation 1.2.

$$\text{RUL} = t_f - t_c \quad (1.2)$$

Le seuil de défaillance dépend fortement du domaine d'application. Les éoliennes étant des actifs de haute valeur, leur défaillance doit être évitée. Par conséquent, les seuils de dégradation devraient être fixés sur des conditions de dégradation critiques, mais avant qu'elles n'évoluent à

une défaillance catastrophique (Zio, 2022). L'estimation de la RUL inclut la distribution de probabilité ou des intervalles de confiance, comme illustre la figure 1.7.

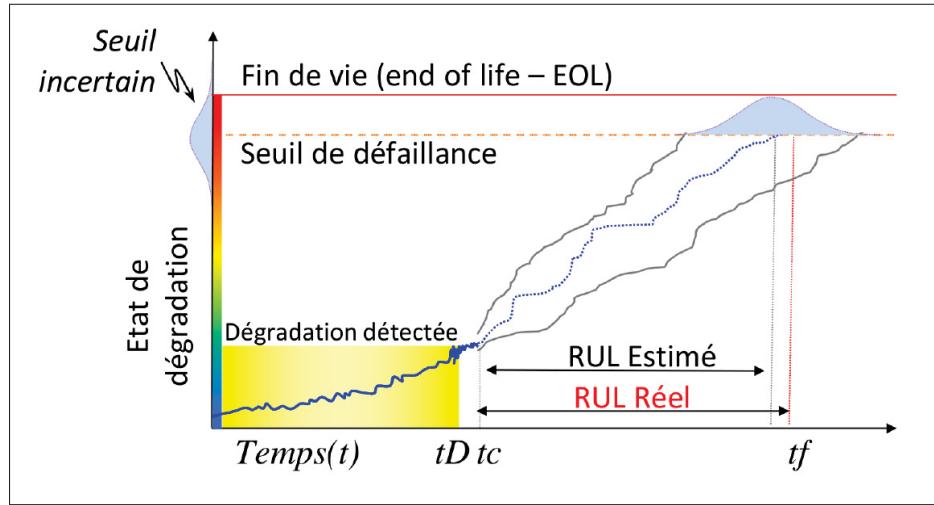


Figure 1.7 Estimation de la RUL avec intervalle de confiance  
Adaptée de Gouriveau *et al.* (2017, p. 21)

Pour chacun des modules qui constituent le processus PHM (illustrés dans la figure 1.6), la littérature identifie trois types de méthodes : méthodes basées sur la physique, méthodes basées sur données et méthodes hybrides (Gouriveau *et al.*, 2017). La méthode basée sur la physique s'applique aux systèmes dont le comportement est décrit de façon détaillée, explicite et complète, avec l'avantage d'exiger relativement peu de données. La structure détaillée et les choix de conception des éoliennes étant des données confidentielles, l'implémentation d'une modélisation physique pour la dégradation des éoliennes reste limitée, probablement restreinte aux équipes de recherche et développement des grands manufacturiers d'éoliennes. De plus, les modèles physiques sont souvent spécifiques à un système et à un mode de dégradation en particulier (Rezamand *et al.*, 2020a). Par conséquent, nous n'avons pas envisagé la modélisation physique pendant les recherches décrites dans cette thèse.

La littérature plus récente distingue deux types de méthodes basées sur les données, à savoir les méthodes statistiques et les méthodes d'IA (Rezamand *et al.*, 2020a). Les méthodes statistiques sont particulièrement pertinentes pour analyser des systèmes dynamiques dont les données

comportent des incertitudes ou des lacunes, par exemple des données manquantes (Rezamand *et al.*, 2020a). Les méthodes d'IA se prêtent particulièrement aux systèmes multidimensionnels, complexes et non linéaires, ne demandant pas des hypothèses à priori. Le prix à payer c'est le besoin d'une grande base de données et le coût numérique important (Rezamand *et al.*, 2020a). Comme indiqué dans la section précédente, les éoliennes décrites par le système SCADA s'approchent davantage du cas de figure analysé avec des méthodes d'IA. Ce type de modélisation a été priorisé dans cette thèse.

Enfin, les modèles hybrides combinent une composante basée sur la physique avec une composante basée sur données. Cela permet d'associer le haut niveau de prédictibilité des modèles basés sur données avec la meilleure fiabilité des modèles physiques (Kong *et al.*, 2020; Yucesan & Viana, 2020a). Les modèles hybrides constituent une piste d'investigation importante pour les systèmes admettant une modélisation physique. Dans (Yucesan & Viana, 2020a), une approche hybride est proposée pour estimer la fatigue dans les roulements principaux des éoliennes. L'approche comprend un modèle physique de dommage cumulatif et un modèle d'apprentissage machine pour tenir compte de l'état de la lubrification. Le modèle ainsi obtenu est alimenté avec des données du système SCADA et des prises de vue pour caractériser le lubrifiant. Dans (Rezamand *et al.*, 2020b), des données de vibration sont associées avec des données SCADA pour la proposition d'un modèle de dégradation conditionné au régime d'opération.

La piste des modèles hybrides a été envisagée au début de notre projet de recherche. En effet, dans le premier article de Conférence, intitulé *Condition Monitoring of Wind Turbine Main Bearing Using SCADA Data and Informed by the Principle of Energy Conservation* (voir l'annexe I), nous avons utilisé une modélisation hybride. Ce premier travail a montré les limites des modèles hybrides dans le cas où seulement les données SCADA sont disponibles. Par conséquent, notre recherche s'est orientée vers les modèles d'IA décrits dans la section suivante.

## 1.3 L'autoencodeur variationnel, un réseau de neurones à variables latentes

L'IA a introduit un nouveau paradigme pour les analyses PHM pour des systèmes complexes décrits par un grand nombre de variables (Zio, 2022). Les trois articles qui constituent cette thèse introduisent des analyses PHM à partir du VAEC, un modèle d'IA basé sur le VAE (Kingma & Welling, 2014). Cette section introduit le modèle VAEC. Les modèles de type réseau de neurones profond (DNN, *Deep Neural Network*) sont brièvement décrits dans la section 1.3.1. La section 1.3.2 définit le VAE. Enfin, la section 1.3.3 présente des variations semi-supervisées et supervisées du VAE et définit le VAEC.

### 1.3.1 Considérations sur les réseaux de neurones : définition, portée, implémentation et mises en garde

L'IA est un domaine très vaste qui inclut plusieurs classes de méthodes rendues pertinentes par la progression des capacités de calcul numérique et de traitement de larges quantités de données. L'apprentissage machine (ML, *Machine Learning*) est une classe de méthodes d'IA projetée pour apprendre des modèles à partir de données et, par conséquent, pour généraliser l'apprentissage à de nouvelles données (Géron, 2022). Les réseaux de neurones (NN, *neural networks*) sont une classe de modèles de ML pouvant modéliser des fonctions complexes grâce (i) à une architecture en réseau combinant des fonctions linéaires et non linéaires, et (ii) à des techniques d'identification de paramètres appropriées (étape d'entraînement du modèle).

Le nom « réseaux de neurones » est une référence aux mécanismes de fonctionnement des neurones cérébraux. L'élément fondamental du modèle NN, le neurone, est montré dans la figure 1.8(a), avec l'identification des principaux éléments qui définissent sa structure — poids, biais et fonction d'activation (Géron, 2022). Les neurones sont disposés en couches (*layers*), comme illustré dans la figure 1.8(b). L'architecture du réseau est caractérisée par le nombre de neurones par couche — ce qui définit la largeur du NN — et le nombre de couches — ce qui définit la profondeur du réseau. Un NN est dit profond (*Deep*) lorsqu'il possède un grand nombre de couches. Il n'existe pas de consensus pour le nombre de couches à partir duquel le

réseau serait considéré profond. Les évidences des expérimentations numériques ont montré que les DNN ont des performances accrues (Naitzat, Zhitnikov & Lim, 2020).

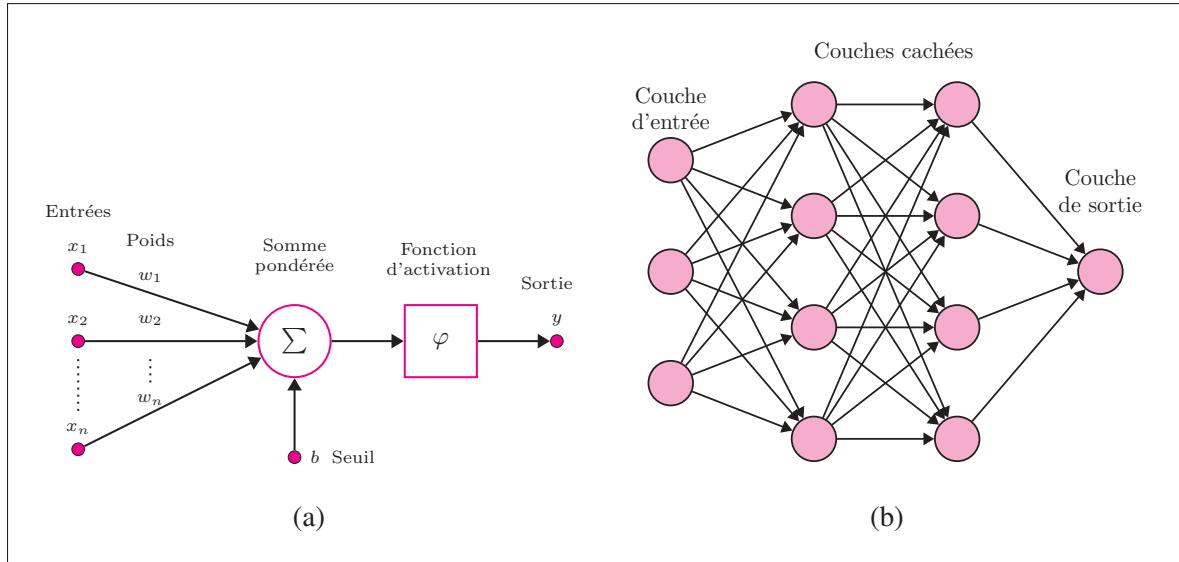


Figure 1.8 Modèle DNN : (a) neuronne et (b) exemple d'architecture

Des études dans divers domaines d'application montrent que les modèles DNN apportent des gains de performance considérables par rapport aux approches classiques (Masood & Ahmad, 2021; Lee *et al.*, 2017; Dodge & Karam, 2017). Cependant, l'usage des méthodes d'IA en général demande quelques précautions. La liste ci-dessous résume les considérations prises dans le cadre de la thèse pour la modélisation par éléments finis. Ces considérations proviennent de sources diverses : des discussions avec le groupe de recherche, des cours, des forums de discussion consacrés au DNN (StackExchange-Contributors, 2018) et le livre « *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow* » (Géron, 2022).

- Validation de la pertinence de l'usage du DNN. En pratique, les DNN sont pertinents surtout lorsque la modélisation physique et les méthodes classiques ont une performance limitée, ou encore parce que leur implémentation est difficile, voire impossible. Par exemple, il serait inapproprié d'utiliser un DNN pour modéliser un comportement linéaire simple à partir d'un petit ensemble de données (surtout si un premier essai avec la méthode de régression linéaire donne des résultats satisfaisants). Cette méthode surdimensionnée

augmente considérablement la complexité du modèle et les sources d'erreur potentielles. Notre recherche s'est d'abord penchée sur une méthode de régression. Le premier article de conférence (Oliveira-Filho, Cambron & Tahan, 2022) montre les limitations d'une telle approche. Cela nous a orientés vers la modélisation basée sur l'IA avec le modèle VAE décrit dans la section 1.3.2.

- Validation des méthodes d'acquisition des données et de la pertinence de la base de données. L'entraînement des DNN demande une base de données représentative du comportement du système d'intérêt. Dans ce sens, l'acquisition des données est une étape fondamentale et doit être planifiée et mise en place de façon à produire des mesures de qualité et informatives pour les phénomènes d'intérêt. Des données incorrectement acquises ou traitées peuvent mener à des modèles biaisés ou faux. L'adage « *garbage in, garbage out* » est une mise en garde pour le fait que l'entraînement d'un modèle avec de mauvaises données va forcément générer un mauvais modèle. La qualité des prédictions est donc liée à la qualité des données utilisées pour l'entraînement.
- Prétraitement des données. Le prétraitement des données pour l'entraînement d'un modèle DNN inclut le filtrage, la consolidation et la normalisation des données. Le filtrage permet de supprimer des valeurs incohérentes ou de sélectionner des conditions d'intérêt pour l'analyse. Dans le cas d'une analyse qui tient compte de multiples états, il est souvent nécessaire de balancer la base de données de façon à obtenir des sous-ensembles de données avec de tailles cohérentes. La normalisation des données consiste à mapper les données sur des intervalles choisis, typiquement [-1,1] ou [0,1]. Les choix pour la normalisation dépendent du type de données et du modèle utilisé. Il s'agit d'une étape courante de la modélisation avec les modèles d'IA pour éviter la divergence dans l'étape d'entraînement.
- Partition de la base de données en ensembles de données pour l'entraînement, validation et test. Le critère de généralisabilité des modèles d'IA est crucial pour assurer que le modèle fonctionne sur de nouvelles données (non considérées lors de l'entraînement). L'entraînement du modèle se fait avec la minimisation d'une fonction coût définie selon le modèle choisi. La comparaison entre les fonctions coût pour les données d'entraînement et les données de validation permet de caractériser la généralisabilité du modèle (sa performance à prédire).

Idéalement, les fonctions coûts pour les deux ensembles de données présentent des taux de convergence semblables. Une convergence plus rapide sur les données d'entraînement indique un cas de surapprentissage (*overtraining*), où le modèle apprend trop spécifiquement les détails de l'ensemble d'entraînement, au détriment de sa capacité à généraliser. À l'opposé, une convergence plus lente sur les données d'entraînement indique un sous-apprentissage (*undertraining*), quand le modèle ne capture pas assez le comportement sous-jacent aux données d'entraînement (Géron, 2022).

- Définition de l'architecture et des hyperparamètres. Les DNN sont hautement personnalisables. Comme point de départ pour l'architecture et hyperparamètres, il est courant d'utiliser des définitions et paramètres disponibles pour un problème similaire documenté. Ensuite, le raffinement du modèle se fait avec une série d'entraînements avec paramètres différents et tenant compte de deux critères en particulier, la convergence et la généralisabilité du modèle. La définition du modèle est une tâche heuristique, guidée par l'observation des performances du modèle selon les paramètres choisis. Les guides d'implémentation des modèles d'IA suggèrent que la base de données de test soit utilisée seulement pour l'évaluation de la performance du modèle (ces données ne sont pas utilisées lors de la définition de l'architecture et le choix des hyperparamètres). Pour cela, les données de test sont choisies et vérifiées avec un soin particulier pour inclure tous les cas de figure retrouvés pour le problème d'intérêt.

Des librairies telles que Tensorflow, Keras et Scikit-Learn sont disponibles pour l'implémentation personnalisable des modèles d'IA. Ces librairies sont bien documentées et de nombreuses discussions en Forum existent pour guider les nombreuses étapes de la définition d'un modèle d'IA. Les étapes pour la définition du modèle d'IA utilisée dans cette thèse sont décrites dans la section 2.2.4.

### **1.3.2 L'autoencodeur variationnel**

Le VAE a été introduit par Kingma & Welling (2014) comme un modèle génératif combinant l'approche des modèles d'apprentissage profond à une approche Bayésienne variationnelle.

Le VAE est employé dans la littérature dans diverses applications. Les deux principales sont (i) la projection d'un espace à haute dimension dans un espace de dimension réduite et (ii) la génération de données synthétiques. La figure 1.9 illustre ces deux applications. L'espace de dimension réduite du modèle VAE est appelé espace latent et est représentatif des propriétés régissant le système dont les mesures définissent un espace physique à haute dimension.

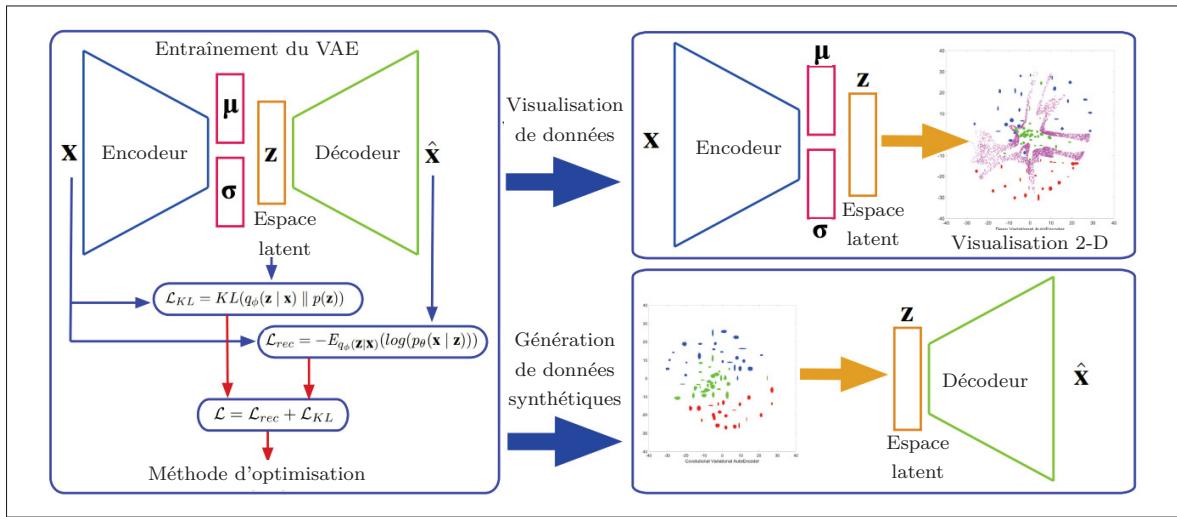


Figure 1.9 Applications des modèles à variables latentes  
Adaptée de Zemouri *et al.* (2019, p. 5442)

Le VAE a été retenu dans cette thèse tenant compte de sa capacité à projeter l'espace à haute dimension des mesures SCADA dans un espace latent de dimension réduite, 2D par exemple, tout en gardant les informations les plus importantes et pertinentes pour décrire l'état du système éolien (Zemouri *et al.*, 2022). De plus, le VAE est un modèle versatile qui admet des variations de son l'implémentation (Tschannen, Bachem & Lucic, 2018).

Il convient de définir le modèle de l'autoencodeur (AE, *Autoencoder*) préalablement à la caractérisation du modèle VAE. Soit  $\mathbf{x} = [x_1, \dots, x_{n_F}]^T$  un vecteur à  $n_F \in \mathbb{N}$  valeurs décrivant l'état physique d'un système arbitraire. L'AE est un DNN qui définit une approximation pour  $\mathbf{x}$  à partir de deux transformations successives, l'encodage et le décodage. L'encodeur  $f_\phi$  transforme  $\mathbf{x}$  dans la variable latente  $\mathbf{z}$  avec une dimension  $n_L \in \mathbb{N}$  telle que  $n_L < n_F$ . Le décodeur  $h_\theta$

transforme  $\mathbf{z}$  en  $\hat{\mathbf{x}}$ , qui a la même dimension  $n_F$  de  $\mathbf{x}$ . Un schéma représentant l'AE est proposé dans la figure 1.10(a).

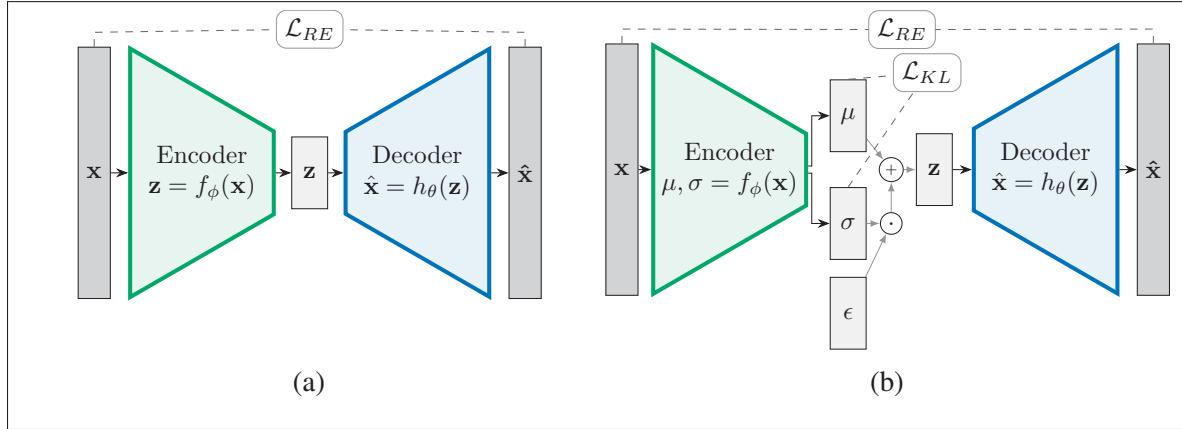


Figure 1.10 Représentation schématique des modèles (a) AE et (b) VAE

Les paramètres de l'AE sont identifiés par la minimisation de la fonction de perte  $\mathcal{L}_{AE} = \mathcal{L}_{RE}$ , où  $\mathcal{L}_{RE}$  est l'erreur de reconstruction donnée par l'équation 1.3. Cet entraînement force les paramètres du modèle AE à prendre des valeurs de sorte que (i) l'encodeur conserve les informations essentielles de l'espace physique et (ii) le décodeur peut reconstruire les caractéristiques d'entrée à partir de la variable de l'espace latent.

$$\mathcal{L}_{RE} = \frac{1}{n_F} \sum_{j=1}^{n_F} (x_j - \hat{x}_j)^2 \quad (1.3)$$

L'espace latent de l'AE manque de régularité. C'est-à-dire que la distance euclidienne dans l'espace latent n'est pas représentative de la relation physique entre les états physiques correspondants dans l'espace physique d'origine. Par conséquent, deux points très proches dans l'espace latent peuvent correspondre à des états physiques très distincts (par exemple, l'opération normale et une condition de défaillance d'un composant critique). Ce manque de régularité du modèle AE limite son usage dans l'analyse de systèmes complexes (Doersch, 2016).

Le modèle VAE résout les limitations de l'AE par l'introduction d'une approximation bayésienne variationnelle dans l'espace latent. La fonction objective utilisée pour entraîner le VAE comprend

deux composants, l'erreur de reconstruction (comme pour l'AE) et l'erreur de Kulback-Liebler (KL) utilisé pour forcer que la distribution des points dans l'espace latent s'approche à la distribution normale centrée réduite. L'espace latent régularisé du VAE lui confère de meilleures propriétés et applicabilité (Doersch, 2016; Zemouri *et al.*, 2022). La figure 1.11 situe le modèle VAE dans le vaste domaine de l'IA.

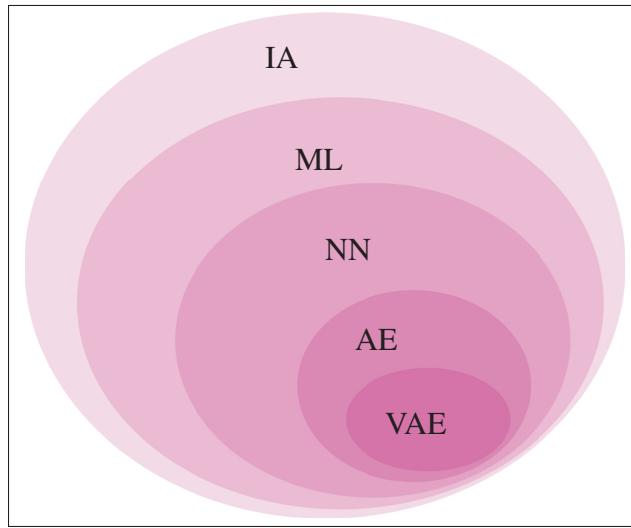


Figure 1.11 Positionnement du modèle VAEC dans le domaine de l'IA

La définition mathématique formelle du VAE inclut la caractérisation probabiliste de l'inférence variationnelle qui définit la structure de l'espace latent. Pour la description détaillée du VAE en termes probabilistes, nous référons à la section 4.2 de cette thèse et à (Kingma & Welling, 2014; Kingma, Welling *et al.*, 2019). La présente section se concentre sur la définition du VAE avec un accent sur l'encodeur, l'espace latent et le décodeur.

L'encodeur du VAE est un DNN avec des paramètres  $\phi$  qui transforme  $\mathbf{x}$  dans la moyenne de l'espace latent  $\boldsymbol{\mu} \in \mathbb{R}^{n_L}$  et dans l'écart-type de l'espace latent  $\boldsymbol{\sigma} \in \mathbb{R}^{n_L}$ , comme l'indique l'équation 1.4.

$$f_\phi : \mathbf{x} \mapsto \{\boldsymbol{\mu}, \boldsymbol{\sigma}\}, \mathbb{R}^{n_F} \rightarrow \mathbb{R}^{n_L} \times \mathbb{R}^{n_L} \quad (1.4)$$

Ensuite, la variable latente  $\mathbf{z} \in \mathbb{R}^{n_L}$  est définie à partir de  $\boldsymbol{\mu}$  et  $\boldsymbol{\sigma}$  avec une astuce de reparamétrisation (*Reparametrization Trick*), qui est donnée par l'équation 1.5, où  $\boldsymbol{\epsilon} \sim \mathcal{N}(\mathbf{0}, \mathbf{1})$

est un vecteur gaussien de dimension  $n_L$  avec un espace d'échantillonnage  $\mathcal{E}$ , et  $\odot$  est le produit élément par élément.

$$g : \{\mu, \sigma, \epsilon\} \mapsto \mathbf{z} = \mu + \sigma \odot \epsilon, \mathbb{R}^{n_L} \times \mathbb{R}^{n_L} \times \mathcal{E} \rightarrow \mathbb{R}^{n_L} \quad (1.5)$$

Enfin, le décodeur du VAE transforme la variable de l'espace latent  $\mathbf{z}$  dans l'approximation  $\hat{\mathbf{x}}$  comme donnée par l'équation 1.6, où  $\theta$  est l'ensemble des paramètres du décodeur.

$$h_\theta : \mathbf{z} \mapsto \hat{\mathbf{x}}, \mathbb{R}^{n_L} \rightarrow \mathbb{R}^{n_F} \quad (1.6)$$

Le schéma pour le VAE est proposé dans la figure 1.10(b).

La fonction coût du VAE est donnée par l'équation 1.7, où  $\mathcal{L}_{RE}$  est l'erreur de reconstruction,  $\mathcal{L}_{KL}$  est la divergence de Kullback-Leibler et le coefficient  $\beta_{KL} > 0$  est défini pour prévenir le problème de *KL-vanishing* (Higgins *et al.*, 2016; Zemouri *et al.*, 2022).

$$\mathcal{L}_{VAE} = \mathcal{L}_{RE} + \beta_{KL} \mathcal{L}_{KL} \quad (1.7)$$

La fonction coût  $\mathcal{L}_{KL}$  mesure la distance statistique entre la distribution de la variable latente et la distribution normale multivariée. L'équation 1.8 donne  $\mathcal{L}_{KL}$  en fonction de  $\mu$  et  $\sigma$ .

$$\mathcal{L}_{KL} = \frac{1}{2} \sum_{j=1}^{n_L} \left( \sigma_j^2 + \mu_j^2 - \log \sigma_j^2 - 1 \right) \quad (1.8)$$

L'entraînement du VAE consiste à minimiser la fonction de perte  $\mathcal{L}_{VAE}$  avec un algorithme tel que la descente de gradient stochastique. Une fois le VAE entraîné, la transformation de la base de données d'entraînement avec l'encodeur projette ces points sur l'espace latent suivant approximativement la distribution normale multivariée. Cette configuration de l'espace latent dépend du coefficient  $\beta_{KL}$  et de la base de données.

### 1.3.3 Implémentations semi-supervisées et supervisées du modèle VAE

Depuis l'introduction du modèle VAE par Kingma & Welling (2014), de nombreuses variations de ce modèle ont été introduites dans la littérature, notamment des modèles qui associent la capacité de représentation latente du VAE avec d'autres fonctions, par exemple la classification binaire, la régression, la classification multi-classes, entre autres (Tschannen *et al.*, 2018).

Le VAE classique (Kingma & Welling, 2014) est un modèle d'apprentissage non supervisé. Peu après la parution de l'article qui a introduit le VAE, Kingma, Mohamed, Jimenez Rezende & Welling (2014) ont traité le problème de la classification semi-supervisée. Leur investigation a porté sur des problèmes pour lesquels les étiquettes ne sont disponibles que pour un petit sous-ensemble de la base de données. En plus de la portion étiquetée de la base de données, les modèles proposés exploitent des données non étiquetées pour améliorer les performances de classification. Trois implémentations semi-supervisées du VAE — M1, M2 et M1+M2 — ont été introduites dans (Kingma *et al.*, 2014). D'après la description des auteurs, le M1 est un modèle discriminatif de caractéristique latente. Le modèle M1 consiste en deux phases d'entraînement distinctes. La première est l'entraînement d'un VAE non supervisé classique. La deuxième phase entraîne un classificateur indépendant en considérant les étiquettes connues et la variable de l'espace latent. L'avantage du modèle M1 est sa simplicité. Cependant, l'entraînement disjoint est une limitation significative (Zhang, Ye, Wang & Habetler, 2020). Le M2 est un modèle semi-supervisé génératif. Le modèle M2 utilise les étiquettes plus tôt dans le processus d'entraînement. La transformation de l'entrée  $\mathbf{x}$  à la variable de l'espace latent  $\mathbf{z}$  comprend deux encodeurs indépendants — pour les données étiquetées et non étiquetées — et un classificateur. Les données étiquetées sont utilisées pour entraîner le classificateur. Le décodeur prend les étiquettes comme entrée. Par rapport au M1, le processus d'entraînement du M2 est accompli en une étape (au lieu de deux), mais est plus coûteux et prend plus de temps en raison d'un nombre beaucoup plus élevé de paramètres et de complexités (Zhang *et al.*, 2020). Le M1+M2 est un modèle semi-supervisé génératif empilé combinant les modèles M1 et M2 (Kingma *et al.*, 2014).

Le modèle VAE Conditionnel (CdVAE) a été introduit dans (Sohn, Lee & Yan, 2015). Ce modèle entièrement supervisé permet la génération de données spécifiques à la condition car son décodeur prend les classes comme entrée. Plus récemment, le VAE Convolutionnel (CvVAE) a été introduit dans (Zemouri *et al.*, 2019). Ce modèle est utilisé pour définir un outil de visualisation à partir de l'espace latent. Dans la littérature, des couches de convolution sont utilisées pour améliorer l'interprétabilité des DNN. D'autres efforts pour rendre les DNN interprétables incluent des techniques telles que la localisation basée sur le gradient, l'analyse de sensibilité avec des stimuli d'entrée sur des caractéristiques et des couches de DNN spécifiques, et la méthode de décomposition de Taylor. Les applications industrielles semblent privilégier le rendu des outils de visualisation pour les transformations globales du DNN, comme dans (Zemouri *et al.*, 2019).

Proteau, Zemouri, Tahan & Thomas (2020) ont introduit une approche basée sur le modèle VAE avec deux étapes d'entraînement indépendantes. Nous nous référons à leur proposition comme le modèle VAEEC. La première étape consiste à entraîner un VAE classique. Dans la deuxième étape, un modèle de DNN est défini comme la combinaison des couches de l'encodeur du VAE avec un modèle pour effectuer de la classification. Le classificateur est un DNN dont la dernière couche est définie avec la fonction d'activation Softmax. Dans le modèle VAEEC, les paramètres de la première étape de l'identification sont utilisés pour initialiser la deuxième formation. La deuxième étape d'entraînement modifie la distribution de l'espace latent en raison de la relaxation des paramètres des couches de l'encodeur. Les auteurs montrent qu'une telle approche permet de séparer les clusters dans l'espace latent. Cependant, le modèle final n'est pas un VAE et les deux étapes d'entraînement sont disjointes.

L'intégration du VAE avec un DNN de classification a été proposée aussi dans (Zhu, Peng & Wang, 2020). Nous nous référons au modèle supervisé résultant comme CdVAEC. Ce modèle introduit la classification à partir de l'espace latent. Puisque la fonction de perte comprend une contribution de l'erreur de classification, la classification influence la distribution de l'espace latent. Néanmoins, (Zhu *et al.*, 2020) n'exploitent pas particulièrement l'espace latent.

Le tableau 1.3 est un sommaire des modèles cités dans cette section.

Tableau 1.3 Implémentations semi-supervisées et supervisées du modèle VAE

Modèle	Référence.	Entraînement	Étapes	Vis.
VAE	(Kingma & Welling, 2014)	Non supervisé	1	-
M1	(Kingma <i>et al.</i> , 2014)	Semi-supervisé.	2	-
M2	(Kingma <i>et al.</i> , 2014)	Semi-supervisé.	1	-
M1+M2	(Kingma <i>et al.</i> , 2014)	Semi-supervisé.	2+	-
CdVAE	(Sohn <i>et al.</i> , 2015)	Supervisé	1	-
CVAEC	(Zhu <i>et al.</i> , 2020)	Supervisé	1	-
CvVAE	(Zemouri <i>et al.</i> , 2019)	Semi-supervisé	1	2D
VAECC	(Proteau <i>et al.</i> , 2020)	Supervisé	2	2D

Dans le cadre de cette recherche, nous avons introduit le modèle VAEC pour obtenir des clusters séparés dans l'espace latent. Il s'agit d'un VAE couplé avec un module pour la classification comme dans la figure 1.12. Ce modèle est décrit en détail dans le premier article de journal publié. Voir section 3.4.1 de cette thèse.

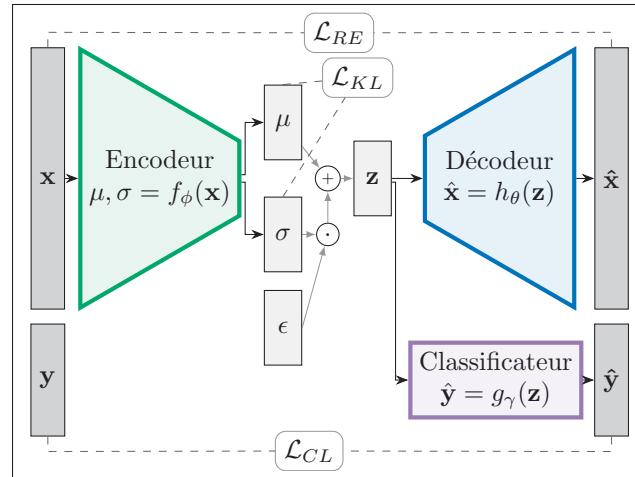


Figure 1.12 Représentation schématique du modèle VAEC

## **1.4 Lacunes et opportunités dans l'analyse PHM des éoliennes avec des données SCADA et des modèles d'IA**

Pour conclure la revue de la littérature, cette section établit une vue d'ensemble sur la littérature couvrant spécifiquement les analyses PHM appliquées aux éoliennes. Il s'agit d'un domaine en plein essor qui motive une intense activité de recherche (Santiago *et al.*, 2024; Badihi, Zhang, Jiang, Pillay & Rakheja, 2022).

Plusieurs sources de données sont utilisées dans la littérature récente, y compris les données provenant du système SCADA, données de vibration, émission acoustique, analyse de l'huile, prises de vue à des positions spécifiques des composants éoliens, etc. Le système SCADA est une source de données privilégiée dans les analyses de surveillance de l'état de santé et du pronostic. Le système SCADA est disponible par défaut dans toutes les éoliennes modernes, il n'y a donc pas des dépenses pour l'installation de nouveaux capteurs. De plus, de nombreux travaux montrent que les modes de dégradation dans les composants critiques ont des signatures dans les mesures du système SCADA. Les données du système de surveillance de l'état de santé et les autres sources de données fournissent souvent des informations à une échelle plus fine que les données SCADA 10-min. Cependant, ces données utilisées ne sont pas disponibles pour la plupart des éoliennes actuellement en opération. Cela limite l'applicabilité d'un grand nombre de méthodes proposées dans la littérature (Badihi *et al.*, 2022; Maldonado-Correa *et al.*, 2020; Rezamand *et al.*, 2020a).

Les modèles d'IA sont souvent utilisés pour adresser le haut niveau de complexité du comportement des éoliennes. La disponibilité de grosses bases de données SCADA favorise l'usage des modèles d'IA. Quelques exemples utilisés pour les analyses PHM des éoliennes sont les DNN, les machines à vecteurs de support (*Support Vector Machine*), les arbres de décision (*Decision Tree*) et les processus Gaussiens, parmi d'autres (Maldonado-Correa *et al.*, 2020; Rezamand *et al.*, 2020a). La richesse des modèles d'IA pose sur leur capacité à tenir compte de relations très subtiles entre les variables, souvent des relations qu'il serait difficile d'appréhender par une modélisation de régression classique sur l'espace physique de grande dimension (Gouriveau *et al.*, 2017). Cependant, ces modèles manquent d'interprétabilité. L'impossibilité

aux opérateurs et décideurs d'expliquer les moyens de calcul limite le niveau de confiance sur les résultats.

Enfin, les travaux sur les analyses PHM pour les éoliennes sont motivés par un but commun, celui de permettre aux opérateurs de mieux planifier les interventions d'inspection et de manutention, surtout par l'adoption de la stratégie de maintenance prédictive. Comparées aux stratégies de maintenance curative (manutention après défaillance ou panne) et systématique (inspections réalisées avec une périodicité fixe), la maintenance basée sur la condition et la maintenance prédictive doivent permettre : de réduire le nombre de défaillances ; de réduire le temps d'arrêt ; d'augmenter le taux de disponibilité ; de favoriser l'exploitation des éoliennes en condition de prolongement de la vie utile (Leite, Araújo & Rosas, 2018; Atamuradov *et al.*, 2017). Les avantages concurrentiels que les analyses PHM peuvent apporter à l'O&M des éoliennes justifient l'intérêt et la participation active des entreprises du secteur de l'énergie éolienne dans ce domaine de recherche appliquée (Santiago *et al.*, 2024; Badihi *et al.*, 2022).

Les deux principales lacunes identifiées dans la littérature du PHM pour les éoliennes sont autour du type de données utilisées et du manque d'interprétabilité des modèles d'IA employés. Dans le chapitre qui suit (chapitre 2), nous précisons les lacunes ayant motivé cette thèse et la méthodologie adoptée pour les adresser.



## CHAPITRE 2

### OBJECTIFS ET MÉTHODOLOGIE

Les objectifs sont indiqués dans la section 2.1. En particulier, la section 2.1.1 met en contexte la production scientifique et les retombées escomptées de la recherche sont décrites dans la section 2.1.2. Enfin, la section 2.2 présente la méthodologie de la recherche.

#### 2.1      Objectifs

L'objectif principal de la recherche doctorale a été d'implémenter le processus d'analyse du pronostic pour les éoliennes à partir des données SCADA. Cinq questions de recherche découlent de cet objectif principal :

**QR1** : Caractérisation des données SCADA provenant des éoliennes et investigation des approches basées sur données qui se prêtent aux données SCADA 10 min. Cette étude a employé de vraies données opérationnelles provenant d'éoliennes suivies par le partenaire industriel. Les données vibratoires et acoustiques ne sont pas prises en compte puisqu'ils ne sont pas disponibles pour la plupart des éoliennes installées à ce jour;

**QR2** : L'enjeu pour la détection d'anomalies c'est d'avoir un descripteur assez sensible pour indiquer une anomalie le plus tôt possible. Dans l'opération des éoliennes, l'anticipation des défaillances est souhaitable puisqu'elle augmente la marge de manœuvre des opérateurs. Dans ce contexte, la deuxième question de recherche a été l'amélioration d'une approche de détection de la dégradation du roulement principal des éoliennes basée sur un modèle régressif (Cambron, Tahan, Masson & Pelletier, 2017).

**QR3** : Le diagnostic fournit des précisions sur le type ou le niveau de l'anomalie ou dégradation. La recherche s'est penchée sur l'identification des modes de dégradation les plus critiques pour les éoliennes ainsi que la classification des anomalies parmi les modes le plus critiques.

**QR4** : La modélisation de la RUL pour des structures et systèmes complexes reste un défi. Une ambition pour la recherche doctorale a été de mettre au point une approche permettant

l'estimation du modèle probabiliste pour la RUL pour les éoliennes. Le modèle devrait utiliser les données SCADA et tenir compte des multiples conditions des éoliennes.

**QR5** : Des modèles d'apprentissage machine permettent de tenir compte du grand nombre de mesures SCADA et d'en extraire une description cohérente avec la réalité physique. Cependant, le manque d'interprétabilité limite la confiance sur les résultats et, a fortiori, le transfert technologique. La QR5 investigue donc la faisabilité d'une modélisation par réseaux de neurones interprétable.

Les 5 questions de recherche couvrent les étapes du processus PHM, comme indiqué dans la figure 2.1.

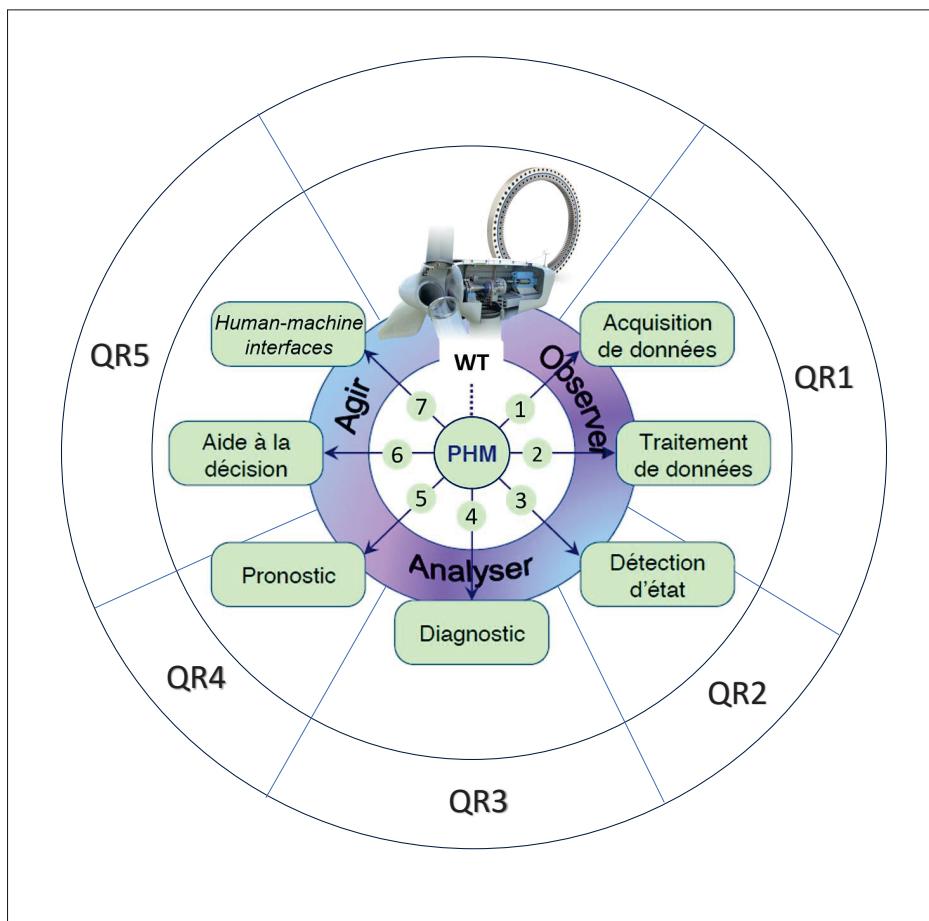


Figure 2.1 Identification des questions de recherche dans le processus d'analyse PHM

### 2.1.1 Mise en contexte des publications scientifiques

Les articles de cette thèse apportent des réponses aux questions de recherche qui motivent notre recherche. Le tableau 2.1 identifie l'ensemble des articles reproduits par la suite dans cette thèse par articles.

Tableau 2.1 Identification des publications issues du doctorat

Article	Date	Journal	Titre	QR	Réf.
Conf. 1	mai 2022	PHM-2022	<i>Condition Monitoring of Wind Turbine Main Bearing Using SCADA Data and Informed by the Principle of Energy Conservation</i>	QR1 et QR2	annexe I
Journal 1	juin 2023	MDPI <i>Energies</i>	<i>Early Detection and Diagnosis of Wind Turbine Abnormal Conditions Using an Interpretable Supervised Variational Autoencoder Model</i>	QR2, QR3 et QR5	ch. 3
Journal 2	Déc. 2023	IEEE Access <i>Section Reliability Society</i>	<i>System Condition Monitoring Based on a Standardized Latent Space and the Nataf Transform</i>	QR2 et QR5	ch. 4
Conf. 2	mars 2024*	PHM-2024	<i>Remaining Useful Life Estimation Based on the System Trajectory in a Latent Space Representation</i>	QR3 et QR5	annexe I
Journal 3	avril. 2024*	IEEE <i>Transactions on Reliability</i>	<i>Remaining Useful Life Estimation Based on Variational Autoencoder Latent Space Representation : Application to Wind Turbines</i>	QR4 et QR5	ch. 5

\* Date de soumission.

### 2.1.2 Retombées escomptées de la recherche

Ce projet de recherche commun entre le Département de génie mécanique de l'ÉTS et Power Factors a été entrepris dans le cadre du programme Mitacs Accélération. Ce programme favorise

l'approximation entre l'académie et l'industrie dans le but d'accélérer le transfert technologique. Le partenaire industriel a participé activement à la recherche, ayant apporté des suggestions dans les étapes de définition de la méthodologie, implémentation, validation et analyse des résultats.

Power Factors compte plusieurs clients canadiens et internationaux qui pourraient bénéficier de l'implémentation des approches proposées dans cette thèse. Les modèles pour la détection, le diagnostic et le pronostic proposés peuvent être bénéfiques pour le secteur de l'énergie éolienne. En effet, les informations obtenues appuient des prises de décision optimales concernant l'opération et la maintenance des éoliennes. En particulier, l'approche de pronostic favoriserait l'adoption de stratégies de maintenance prédictive.

En favorisant l'énergie éolienne, la recherche veut contribuer à l'augmentation du taux de pénétration des énergies renouvelables. Cette recherche est en lien avec trois des objectifs de développement durable de l'ONU, à savoir l'objectif 7 — Énergie propre et d'un coût abordable, l'objectif 9 — Industrie, innovation et infrastructure et l'objectif 13 — Mesures relatives à la lutte contre les changements climatiques.

## 2.2 Méthodologie

Cette section fournit une vue d'ensemble sur la méthodologie adoptée pour répondre aux questions de recherche. De plus, les chapitres 3, 4 et 5 fournissent les choix méthodologiques particuliers à chacun des articles constituant cette thèse.

### 2.2.1 Hypothèses et portée de la recherche

Cette recherche s'est concentrée sur les éoliennes commerciales modernes avec les configurations suivantes : posées sur terre (*onshore*), *upwind*, axe horizontal auto-orientable sur le plan horizontal, rotor avec trois pales, puissance nominale de l'ordre d'un mégawatt, puissance active variable avec contrôle via angle de calage ajustable.

Les éoliennes qui font l'objet de cette recherche sont supposées être munies du système SCADA. À l'image de la majorité des éoliennes en opération aujourd'hui, les éoliennes d'intérêt ne sont pas munies du système de surveillance de l'état de santé. Des données de vibration, d'émission acoustiques ou d'analyse d'huile ne sont donc pas disponibles. En vue des données disponibles et du niveau de complexité structurelle des éoliennes, la recherche a priorisé des modèles basés sur les données SCADA. De plus, les modèles physiques à l'échelle des matériaux ou des interfaces entre composants (fatigue, fissuration, fluage) sont hors de la portée de la recherche.

Pour délimiter la portée de recherche, nous introduisons quelques définitions ci-dessous :

- Condition nominale, opération nominale, condition saine (*HY, healthy*) : l'éolienne opère selon la courbe de puissance spécifiée par le fabricant. Les mesures restent dans l'enveloppe d'opération nominale et le système SCADA n'indique aucune exception.
- Exception indiquée par le système SCADA : notification, alarme ou annotation par le système SCADA lorsque n'importe quelle valeur mesurée est hors des valeurs acceptables selon les critères définis par le manufacturier. Ces indications font partie du fonctionnement des éoliennes.
- Condition anormale, opération anormale : Une ou plusieurs mesures sont hors de l'enveloppe d'opération nominale. Le système SCADA notifie des exceptions selon des critères établis par le fabricant. Il se peut qu'une condition anormale ne soit pas notifiée par le système SCADA (par exemple la température d'un composant anormalement élevée, mais encore en dessous du seuil de notification par le système SCADA). Une condition anormale est irréversible.
- Dégradation, mode de dégradation, condition dégradée : l'intégrité d'un composant ou sous-système a été atteinte. Il s'agit d'une condition irréversible.
- Défaillance : une dégradation négligée peut évoluer jusqu'à la défaillance. La défaillance d'un composant ou sous-système implique l'impossibilité d'opération de l'éolienne. En pratique, des réparations sont requises pour remettre l'éolienne en opération.

La portée de la recherche doctorale est limitée à l'opération en condition normale, anormale ou dégradée des éoliennes ayant des signatures sur les mesures SCADA. C'est-à-dire que les conditions d'intérêt sont celles qui perturbent les mesures obtenues par le système SCADA.

En outre, la recherche priorise des conditions anormales et dégradations impactant quatre composants critiques : rotor, roulement principal, boîte de vitesses et générateur.

### 2.2.2 Base de données SCADA

Les données utilisées dans le cadre du doctorat proviennent de deux parcs éoliens en opération. Ces données ont été fournies par le partenaire industriel Power Factors. Le tableau 2.2 indique les caractéristiques approximatives des deux parcs éoliens analysés.

Tableau 2.2 Identification des bases de données SCADA

Parc Éolien *	Lieu	Nombre d'éoliennes	Puissance nominale	$V_{in}$ , $V_n$ , $V_{out}$ **	Période
A	Québec	>70	$\approx 1.5\text{MW}$	3.5 m/s, 11.5 m/s, 20 m/s	>2 ans
B	Texas	>110	$\approx 2\text{MW}$	3.5 m/s, 11.5 m/s, 20 m/s	$\approx 1.5$ an

\* : Parcs éoliens caractérisés de façon anonyme par souci de confidentialité.

\*\* :  $V_{in}$  : vitesse de démarrage ;  $V_n$  : vitesse nominale ;  $V_{out}$  vitesse d'arrêt.

Les mesures SCADA sont continuellement acquises à une fréquence qui dépend de chaque capteur. Les données sont stockées sous forme de série temporelle avec un pas de temps de 10 minutes, où chaque valeur est la moyenne des valeurs mesurées sur les 10 minutes (IEC, 2022). Au total, 35 chaînes de mesure SCADA ont été rendues disponibles pour chaque éolienne des parcs éoliens analysés. Avoir au moins un an de données est important pour éviter des biais liés aux variations saisonnières.

Outre les données SCADA, nous avons eu accès aussi aux fichiers d'exception (*log files*) du système SCADA, ainsi qu'aux rapports de suivi des cas (*Case Manager*) qui sont remplis suite aux interventions d'inspection et de maintenance. Le système SCADA génère automatiquement des fichiers indiquant les événements qui constituent des exceptions à la condition d'opération normale. Les définitions précises de l'enveloppe d'opération selon le fabricant ne sont généralement

pas accessibles. Cependant, des analyses sur plusieurs occurrences d'une exception indiquée par le système SCADA permettent d'inférer certains critères. Le plus souvent, les indications d'exception du système SCADA peuvent être associées à des règles logiques binaires appliquées sur les mesures. Par exemple, l'exception « Surchauffe du roulement principal » est déclenchée lorsque la température de ce composant dépasse le seuil de 60°C.

Les rapports de suivi des cas sont des documents détaillés qui contiennent des informations multiples, avec quelques entrées calculées automatiquement et aussi des champs remplis par les techniciens. Ces rapports incluent les identifiants spécifiques à chaque éolienne et à chaque événement, ainsi qu'aux techniciens ayant apporté des modifications au document et les instants des interventions sur place. Sur ces documents, les techniciens et analystes peuvent inclure des informations détaillées sur les observations et analyses, incluant des symptômes observés, la classe de l'observation, la cause possible, la cause confirmée, des événements ou interventions éventuellement en lien avec l'événement, etc.

La section suivante décrit comment les données SCADA brutes sont utilisées pour définir la base de données caractérisant les conditions d'opération des éoliennes.

### **2.2.3 Préparation de la base de données normalisée et étiquetée**

La définition de la base de données normalisée et étiquetée à partir des données brutes SCADA comprend quatre étapes, à savoir : (1) Sélection des mesures SCADA à être utilisées comme descripteurs, (2) filtrage des données, (3) normalisation des données et (4) labellisation des données.

Étape 1 : Sélection des mesures SCADA à être utilisés comme descripteurs. Les mesures SCADA retenues comme descripteurs pour l'analyse PHM sont listées dans le tableau 2.3. Il convient de souligner que, lorsque les mesures de vibration ne sont pas disponibles, les mesures de température sont privilégiées comme descripteurs pour des conditions d'opération anormales et dégradations dans des composants critiques des éoliennes (Lebranchu, Charbonnier, Bérenguer & Frédéric, 2014; Cambron *et al.*, 2017; Beretta, Julian, Sepulveda, Cusidó & Porro,

2021a). Aussi, les 22 autres mesures SCADA n'ont pas été retenues puisqu'elles apportent peu ou aucune information à l'ensemble des mesures retenues pour décrire l'état des éoliennes. Cela est dû à trois facteurs principaux. Premièrement, certaines variables sont fortement corrélées entre elles. Deuxièmement, la moyenne sur 10 minutes efface toute information significative des mesures variant à une fréquence très élevée — c'est le cas pour la fréquence électrique et la tension. Troisièmement, certaines variables sont rares, c'est-à-dire que leurs séries temporelles présentent de nombreuses entrées non numériques.

Tableau 2.3 Mesures SCADA utilisées comme descripteurs

Mesure	Symbole	Unité	LI*	LS*
Vitesse du vent	$WS$	m/s	0	31
Vitesse de rotation du rotor	$n_{ROTOR}$	rpm	0	18
Puissance active	$P$	kW	0	2000
Temp. ambiante	$T_{AMB}$	°C	-25	45
Temp. nacelle	$T_{NAC}$	°C	-20	70
Temp. roulement principal	$T_{BEA}$	°C	-20	70
Temp. roulement de la boîte de vitesses	$T_{GBX-BEAR}$	°C	0	100
Temp. huile de la boîte de vitesses	$T_{GBX-OIL}$	°C	0	100
Temp. génératrice position 1	$T_{GEN1}$	°C	-10	140
Temp. génératrice position 2	$T_{GEN2}$	°C	-10	140
Temp. refroidissement du générateur	$T_{GEN-COOL}$	°C	-10	120
Temp. boîtier du moteur pitch	$T_{AX-BOX}$	°C	0	60
Temp. boîtier de batterie position 1	$T_{BAT-BOX1}$	°C	0	45

\* LI = limite inférieure, LS = limite supérieure

Étape 2 : Filtrage et normalisation des données. Les mesures issues du système SCADA présentent souvent des valeurs non numériques (*NaN*) ou des valeurs inconsistantes avec la réalité physique. Par exemple, lorsqu'une mesure de température ambiante dépasse 100°C. Ces occurrences peuvent être associées de défauts de mesure, de traitement ou transfert des données. Pour éviter que ces données influencent les modèles et analyses, il est courant de faire une étape de filtrage des données. Des filtres passe-bande spécifiques à chaque mesure sont définis avec des limites qui peuvent être définies à partir de l'analyse statistique des mesures sur l'ensemble du parc éolien. Ces limites sont indiquées au tableau 2.3. Pour les bases de données analysées, cette étape de filtrage a supprimé moins de 2% des données. Pour établir l'analyse sur l'état

des éoliennes lorsqu’elles sont en opération, une seconde étape de filtrage a été incluse pour sélectionner les points de données vérifiant  $P(kW) > 0$  et  $n_{ROTOR}(rpm) > 0$ . De plus, les données correspondant à la condition de bridage (*Curtaillement*) ont aussi été enlevées, car cela représente une condition différente de l’opération nominale.

Étape 3 : Après les deux étapes de filtrage, chaque mesure est normalisée en utilisant les limites dans l’intervalle [0, 1] pour être utilisée dans les modèles DNN. La normalisation Min-Max (Patro & Sahu, 2015) utilise les limites du tableau 2.3. Aucune méthode de remplissage des données n’a été utilisée.

Étape 4 : Labellisation des données. Des modèles d’apprentissage machine supervisés ont été utilisés dans plusieurs étapes de la recherche. Ces modèles demandent des données labellisées. Les conditions ont été identifiées à partir des fichiers d’exception et les rapports d’O&M avec la supervision des experts de chez le partenaire industriel. La tâche de labellisation des ensembles de données (*datasets*) utilise les mesures brutes et les fichiers d’exception du système SCADA, ainsi que des rapports de suivi des cas. Les travaux de surveillance de l’état de santé basés sur les données SCADA analysent le plus souvent des anomalies liées à la température, notamment celles impliquant la surchauffe de composants critiques (Beretta *et al.*, 2021a; Badihi *et al.*, 2022). Notre recherche s’est concentré sur les conditions d’opération d’intérêt listées dans le tableau 2.4. Nous nous référerons aux travaux de Rezamand *et al.* (2020a) et Cambron *et al.* (2017) pour des illustrations de certains de ces modes de dégradation.

Tableau 2.4 Conditions d’intérêt pour les éoliennes

ID	Description
HY	Condition saine
BEA	Surchauffe du roulement principal
GBX	Surchauffe de l’huile de la boîte de vitesses
GEN	Surchauffe du bobinage du stator du générateur
ICE	Givrage des pales

Pour détecter précocement un changement de condition opérationnelle, les points de données sélectionnés pour représenter une condition donnée peuvent dépasser l’ensemble des points de

données avec une exception SCADA signalée. Pour une condition d'intérêt, les trois étapes pour définir l'ensemble de données sont les suivantes : (i) sélectionner un sous-ensemble d'éoliennes opérant dans la condition d'intérêt. Cette étape utilise les fichiers d'exception SCADA et les rapports de suivi des cas. (ii) Énumérer les cas de dégradation à partir du sous-ensemble d'éoliennes défini à l'étape précédente. Le résultat de cette étape est une liste de cas, chacun identifié par l'identifiant de l'éolienne, l'instant de début et l'instant de fin. (iii) Rassembler les données correspondant aux cas énumérés à l'étape précédente. L'ensemble de données résultant comprend des points de données de plusieurs éoliennes et est censé représenter la condition globale d'intérêt.

La figure 2.2 illustre la démarche de définition des jeux de données labellisées pour la condition anormale de surchauffe de l'huile de la boîte de vitesses (*gearbox oil overtemperature*). La température de l'huile de boîte de vitesses  $T_{GBX-OIL}$  est la mesure la plus sensible pour une telle condition. La figure 2.2 indique  $T_{GBX-OIL}$  dans un intervalle comprenant l'exception SCADA correspondante. Le seuil de comportement anormal est défini manuellement en considérant plusieurs échantillons pour la même condition, ce qui conduit à la définition de l'instant de début réel  $t_I^{\Omega_k}$  et de l'instant de fin  $t_F^{\Omega_k}$  qui délimitent le rectangle *extended dataset* dans la figure 2.2.

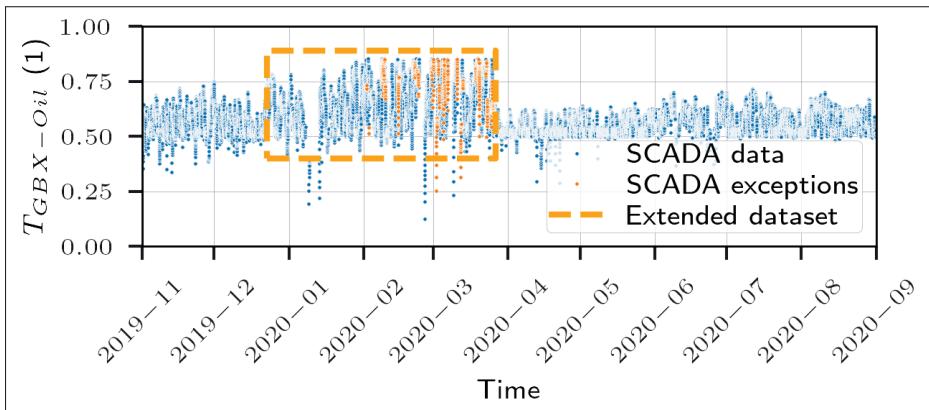


Figure 2.2 Procédure pour la définition des ensembles de données pour la condition de surchauffe la boîte de vitesses

Les ensembles de données résultant des étapes précédentes ont des nombres différents de points. Une technique d'augmentation des données basée sur le modèle VAE est donc utilisée

pour équilibrer les ensembles de données (Tanner & Wong, 1987; Chadebec, Thibeau-Sutre, Burgos & Allassonnière, 2022). Plus précisément, chaque ensemble de données de condition homogène est utilisé pour entraîner un modèle VAE. Son espace latent est le support pour générer aléatoirement des points en utilisant la distribution gaussienne. Ensuite, le décodage VAE des points de l'espace latent génère l'ensemble de données augmenté (Chadebec *et al.*, 2022). Le nombre cible de points pour chaque ensemble de données est  $n = 10000$ .

La base de données résultante est une collection de 5 ensembles de données avec  $n = 10000$  points de données chacun. Pour les besoins de l'entraînement et de l'évaluation, cette base de données est partitionnée en trois bases de données : entraînement (avec 50% de tous les points de données), validation (20%) et test (30%).

Il convient de mentionner que certaines exceptions SCADA n'ont pas d'intérêt pratique pour les analyses de détection, diagnostic ou pronostic. Cela inclut certaines conditions liées aux conditions météorologiques. Par exemple, l'arrêt dû à une vitesse de vent inférieure à  $V_{in}$ .

#### **2.2.4      Implémentation numérique du modèle VAEC**

Le langage Python a été retenu pour l'implémentation numérique des méthodes proposées. Les projets Python ont été créés sur l'éditeur Microsoft Visual Studio Code. Jupyter Notebook a été utilisé lors des étapes de conception, développement et raffinement des codes, ainsi que pour les analyses et affichages des résultats. Plusieurs librairies Python ont été utilisées, notamment : numpy, pandas, csv, os, datetime, matplotlib et seaborn. De plus, Tensorflow, Keras, Scikit-Learn ont été utilisés pour l'implémentation du VAE et de ses variations. En particulier, Tensorflow version 2.10 a été configuré pour utiliser l'unité de traitement graphique (GPU), ce qui accélère les entraînements des DNN.

L'architecture du VAEC est en partie déterminée par les choix des mesures pour représenter le système, le nombre de classes analysées et la dimension de l'espace latent. La sélection de  $n_F = 13$  mesures SCADA pour représenter l'état du système éolien détermine la dimension de l'entrée de l'encodeur et de la sortie du décodeur. Pour atteindre l'objectif d'avoir un outil de

visualisation à partir de l'espace latent, sa dimension a été fixée à  $n_L = 2$ . De plus, la sortie du classificateur est une couche avec  $n_C = 5$  noeuds, correspondant aux 5 conditions analysées (HY, BEA, GBX, GEN, ICE).

Il reste à définir la profondeur (nombre de couches cachées) et la largeur (nombre de neurones par couche) des réseaux définissant l'encodeur, le décodeur et le classificateur. Cette architecture du VAEC a été définie suite à une étape itérative qui a consisté d'évaluer les fonctions coûts obtenues suite à l'entraînement avec des jeux de paramètres choisis et ajustés de façon heuristique. Cette analyse a d'abord visé à atteindre la convergence du modèle et, ensuite, à satisfaire le critère de généralisation du modèle sur les données d'entraînement et de test. L'architecture retenue pour le VAEC et utilisée dans les trois articles publiés est la suivante :

- L'encodeur englobe 3 couches cachées. Le nombre de nœuds par couche est, successivement, 13 (couche d'entrée), 32, 16, 8 et 2 (couche de sortie). La fonction d'activation *ReLU* a été utilisée dans la couche d'entrée. Les couches cachées utilisent la fonction d'activation *tanh*. De plus, une couche de *dropout* de 10 % est ajoutée après la couche de 32 nœuds pour prévenir le surapprentissage (Géron, 2022).
- Le décodeur est symétrique à l'encodeur, ses couches successives ont donc 2, 8, 16, 32 et 13 nœuds). La fonction d'activation *tanh* est utilisée dans toutes les couches sauf la couche de sortie, pour laquelle la fonction d'activation linéaire a été choisie.
- Le classificateur a été construit avec 4 couches cachées comptant, successivement, 128, 64, 32 et 16 nœuds par couche. La couche d'entrée de dimension 2 est l'espace latent. La fonction d'activation *tanh* est utilisée dans la couche d'entrée et dans les couches cachées. La couche de sortie du classificateur est une couche avec 5 nœuds utilisant la fonction d'activation *Softmax*.

L'algorithme Adam (Adaptive Moment Estimation) (Kingma & Ba, 2014) a été retenu pour l'entraînement du VAEC. Les hyperparamètres d'entraînement retenus sont les suivants : taux d'apprentissage de 0.0001, clipvalue de 0.3, nombre d'époques de 1024, taille de lot de 128.

## CHAPITRE 3

### EARLY DETECTION AND DIAGNOSIS OF WIND TURBINE ABNORMAL CONDITIONS USING AN INTERPRETABLE SUPERVISED VARIATIONAL AUTOENCODER MODE

Adaiton Oliveira-Filho<sup>1</sup> , Ryad Zemouri<sup>2</sup> , Philippe Cambron<sup>3</sup> , Antoine Tahani<sup>1</sup>

<sup>1</sup> Department of Mechanical Engineering, École de Technologie Supérieure, 1100 Rue Notre Dame O, Montreal, QC H3C 1K3, Canada;

<sup>2</sup> Research Center of Hydro-Québec, 1800 Bd Lionel-Boulet, Varennes, QC J3X 1S1, Canada;

<sup>3</sup> Power Factors, 7005 Boulevard Taschereau, Brossard, QC J4Z 1A7, Canada.

Article publié dans « MDPI Energies » le 6 Juin 2020.

**Abstract :** The operation and maintenance of wind turbines benefit from reliable information on the wind turbine condition. Data-driven models use data from the supervisory data acquisition system. In particular, great performance is reported for artificial intelligence models. However, the lack of interpretability limits their effective industrial implementation. The present work introduces a new condition-monitoring approach for wind turbines featuring a built-in visualization tool that confers interpretability upon the model outcomes. The proposed approach is based on a supervised implementation of the variational autoencoder model, which allows the projection of the wind turbine system onto a low-dimensional representation space. Three outcomes follow from such representation : a health indicator for the early detection of abnormal conditions, a classifier providing the diagnosis status, and a visualization tool depicting the wind turbine condition as a trajectory in a 2-D plot. The approach is implemented with a vast database. Two case studies demonstrate the potential of the proposed approach. The proposed health indicator detects the main bearing overtemperature 11 days before the control system alarm, one week earlier than a competing approach. Study cases illustrate that the built-in visualization tool enhances the interpretability and trust in the model outcomes, thus supporting wind turbine operation and maintenance.

**Keywords :** Wind turbines ; condition monitoring ; variational autoencoder ; SCADA data ; early detection ; diagnosis ; model interpretability.

### 3.1 Introduction

The rapid and assured growth of the global wind power capacity results from efforts to decarbonize energy production. This trend is supported by and depends on a competitive LCOE for a Wind Turbine (WT). Notably, O&M expenditures correspond to a significant share of the WT LCOE, with estimations ranging from 20% to 30% (Dao, Kazemtabrizi & Crabtree, 2019; Costa, Orosa, Vergara & Fernández-Arias, 2021).

O&M in situ interventions include inspections, preventive maintenance, and curative maintenance. Currently, scheduling of the WT O&M interventions relies on data-driven analysis to a limited extent. Typically, Performance Monitoring uses data from the WT SCADA system to detect overall underperformance, while Condition Monitoring (CM) approaches aim at detecting and diagnosing abnormal conditions in specific critical components based on the SCADA data (Nicod, Chebel-Morello & Varnier, 2017; Tautz-Weinert & Watson, 2017).

The WT CM literature pays particular attention to Artificial Intelligence (AI) models. This interest is due to the availability of ever-increasing databases from operating wind farms, not to mention the proven performance of AI-based models. Among these, the VAE model (see Kingma & Welling (2014)) stands out given its ability to analyze systems characterized by a large number of features, including features with a noisy and stochastic nature, as is the case of the measures from the WT system (Helbing & Ritter, 2018; Badihi *et al.*, 2022; Zemouri *et al.*, 2019). Nevertheless, the effective implementation of AI-based models in WT CM requires scientific and technological gaps to be addressed, notably the lack of interpretability. Visualization tools are among the main approaches to overcoming the black-box nature of AI models (Gilpin *et al.*, 2018; Lipton, 2018). The VAE low-dimensional latent space is used to develop visualization tools allowing one to interpret the model outcomes. Proven results are reported in applications emerging from diverse domains of study (Tits, Wang, Haddad, Pagel & Dutoit, 2019; Proteau *et al.*, 2020; Banko, Maffettone, Naujoks, Olds & Ludwig, 2021; Cheng & Chen, 2022; Zemouri *et al.*, 2019). To the best of our knowledge, the use of the VAE latent space as a visualization tool is not exploited in any publication on WT CM.

The present work aims to exploit the VAE model in the definition of a CM approach for WT with a built-in visualization tool for enhanced interpretability. Precisely, the proposed approach is based on a supervised implementation of the VAE. The dimension reduction capability of the VAE model allows for the definition of a unified approach for (1) the early detection of abnormal conditions, (2) the diagnosis of the abnormal conditions, and (3) the definition of a visualization tool in which the evolution of the wind turbine condition is represented in a 2-D plot.

### 3.1.1 Related Works

The present work introduces a supervised implementation of the VAE model that leads to the detection and diagnosis of abnormal conditions, as well as a visualization tool. Previous works are briefly reviewed below.

#### 3.1.1.1 Detection of Wind Turbine Abnormal Conditions Using the VAE Model

The literature on VAE-based WT detection includes two kinds of analysis. The models can focus on subsystems and critical components or rather consider the overall WT condition. Among the former, Zhao, Liu, Hu & Yan (2018a) use the AE model to detect abnormal conditions and anticipate failure in the gearbox, the main shaft bearing, and the generator. Wang, Zhang, Xu & Liu (2018) use the AE model to perform CM of the WT breakage system. A wavelet-enhanced AE model is proposed by Yuan *et al.* (2019) to detect blade icing. Hemmer, Klausen, Van Khang, Robbersmyr & Waag (2020) define a VAE-based HI for the WT main bearing condition. The authors exploit, in particular, the VAE latent space, the HI being a function of the latent variables.

CM approaches analyzing the overall WT condition are often called system-wide CM. Jiang, Xie, He & Yan (2017) use a denoising AE to deal with the non-linear and stochastic WT measures. Wu *et al.* (2019) exploit the denoising AE similarly. In both cases, the denoising AE allows the capture of different information from the features. Meanwhile, Renström, Bangalore & Highcock (2020) use the VAE model in an overall WT CM approach based uniquely on SCADA data. The

authors analyze the influence of the model architecture and Gaussian denoising. In particular, they conclude that the range of choices for the VAE architecture is broad, with multiple dimensions of the VAE latent space leading to similar performance. Moreover, their work reports that no noise lead to the best performance when using SCADA 10-min measures (Renström *et al.*, 2020).

### **3.1.1.2 Diagnosis of Wind Turbine Abnormal Conditions Using the VAE Model**

Diagnosis aims at characterizing the detected abnormal behaviors in terms of severity (Cheng & Chen, 2022), category (Lei, Liu & Jiang, 2019), location, and root causes (Roelofs, Lutz, Faulstich & Vogt, 2021). We refer to Stetco *et al.* (2019) for a comprehensive review of diagnosis approaches for WT.

The VAE model successfully diagnoses defaults in rolling bearings in (Cheng & Chen, 2022). The unsupervised training of the VAE allows for diagnosis due to the database characteristics and specific modelling choices. First, the database emerges from a controlled laboratory setting. Second, the available data include vibratory measures, which have proven accuracy in detecting abnormal conditions in rotating components (Peeters, Guillaume & Helsen, 2018; Barszcz, 2019). Finally, the authors select the key features using feature engineering specific to the conditions of interest.

Roelofs *et al.* (2021) investigated the use of the component-wise VAE reconstruction error to diagnose the WT condition. However, the classical unsupervised VAE seems insufficient to diagnose wind turbines when only SCADA data are available (Roelofs *et al.*, 2021). The intricate nature of the features limited the success of their proposition, with a weak causal relation between some components of the reconstruction error and the abnormal behavior under analysis.

Previous works achieve good performance in diagnosis by combining the VAE with other DNN models in the framework of generative adversarial networks (Zhang, Zhang & Cai, 2022; Liu *et al.*, 2021b). Liu *et al.* (2021b) introduced a diagnosis approach for the categorization of abnormal conditions in multiple WT subsystems. The authors proposed the sparse dictionary learning-based adversarial variational auto-encoders (AVAE SDL) model and used only measures from

the SCADA system. Scores from the reconstruction errors specific to each SCADA measure lead to the categorization of abnormalities. The AVAE\_SDL-based diagnosis correctly categorizes selected study cases, outperforming competing approaches regarding the frequency of false alarms. More recently, Zhang *et al.* (2022) proposed a diagnosis approach for WT bearings using vibration signals. The authors reported good accuracy for multiple case studies with typical bearing vibration data and data with added noise. The conditional variational generative adversarial network (CVAE-GAN) model allowed for addressing two major problems in other vibration-based approaches, namely the imbalance of databases and the high frequency of false alarms.

### **3.1.1.3 VAE Model as a Visualization Tool**

The VAE latent space is exploited as a visualization tool in diverse domains, including audio and speech processing (Tits *et al.*, 2019), manufacturing (Proteau *et al.*, 2020), X-ray diffraction (Banko *et al.*, 2021), bearing diagnosis (Cheng & Chen, 2022), and hydrogenerator monitoring (Zemouri *et al.*, 2019). The VAE-based visualization tools are reported to outperform competing approaches such as Principal Component Analysis and t-distributed Stochastic Neighbour Embedding Projection (Zemouri *et al.*, 2019; Proteau *et al.*, 2020). Zemouri *et al.* (2019) use the VAE to define a 2-D visualization and classification tool for partial discharge, which is a consequential symptom of degradation in hydrogenerators. Proteau *et al.* (2020) use the VAE model to detect early changes in the state of machining processes, with the corresponding latent space serving as a visualization tool. The authors recently proposed a prognosis approach from the VAE latent space (Proteau *et al.*, 2022). Cheng & Chen (2022) propose a diagnosis approach for ball bearings based on a VAE model. They show, in particular, that selecting the most sensitive features for a specific degraded condition can enhance cluster disentanglement in the latent space.

### 3.1.2 Main Contributions

To our knowledge, no previous works have used the VAE model to simultaneously address the WT CM and render a visualization tool for enhanced interpretability. The present work fills this gap. The three main contributions of the present paper are summarized below :

- This work introduces a new supervised implementation of the VAE model, hereafter referred to as the VAEC model, for detecting and diagnosing the WT operating conditions. The VAEC allows the representation of the WT condition in a low-dimensional and physically representative space.
- The VAEC latent space as a visualization tool for the WT condition is introduced and illustrated with two case studies. The proposed visualization tool derives directly from the VAEC model when the latent space dimension is set as two or three. The resulting 2-D or 3-D visualization is interpretable and is expected to enhance trust and confidence among O&M practitioners.
- An HI is introduced based on the VAEC encoding of SCADA datasets into the VAEC latent space. The proposed HI uses the Mahalanobis distance to measure how far data points are from the healthy cluster. The Exponentially Weighted Moving Average (EWMA) control chart is then used to detect trends in the daily average of the Mahalanobis distance (Roberts, 1959). Tests with real data show that the proposed HI allows the detection of abnormal conditions earlier than competing approaches.

### 3.1.3 Paper Organization

This paper is organized as follows. Section 3.2 describes the SCADA database from an operating wind farm. Section 3.3 reviews the VAE model. Section 3.4 introduces the VAEC model. It is then used in an approach comprising both CM and a visualization tool. Section 3.5 presents the methodology. Section 3.6 shows encouraging results from the implementation of the proposed approach in case studies. Finally, Section 3.7 concludes the work.

### 3.2 SCADA Database

This work uses data from a North American wind farm comprising over a hundred WTs. The database covers two years and four months of operation, a period that includes occurrences of multiple abnormal behaviors, some of which characterize the degradation or failure of specific critical components. The machines are horizontal and upwind and have three-blade rotors of nearly 90 m diameter and a hub height of 80 m. Each WT has a rated power of  $P_n = 1.85$  MW and a rated wind speed of  $V_r = 13$  m/s. The WTs are pitch-controlled with cut-in wind speed  $V_{in} = 3.5$  m/s and cut-off wind speed  $V_{out} = 20$  m/s.

Temperature measures are commonly used to detect abnormal conditions in WT components when no vibratory measure is available Beretta *et al.* (2021a), which is the case for the WTs analyzed in the present study. Five interest conditions are summarized in Table 3.1. HY is the reference representing healthy operation. Four of the selected conditions consist of overtemperature at critical components. Ice accretion on blades can happen in WTs operating under icing conditions, eventually resulting in non-winterized WTs (Hochart, Fortin, Perron & Ilinca, 2008), as is the case for the units under analysis.

Tableau 3.1 WT conditions of interest to demonstrate the proposed CM approach

ID	Description
HY	Healthy condition
BEA	Main bearing overtemperature
GBX	Gearbox oil overtemperature
GEN	Generator stator winding overtemperature
ICE	Ice accretion on blades
SWT	Gearbox oil overtemp. from thermal switch

The database made available for the present research comprises 35 SCADA measures for each WT. The SCADA system comprises multiple sensors, including geometrical, kinematic, thermal,

and electrical measures. The SCADA measures are continuously acquired at frequencies that depend on each sensor and then stored following the 10-minute aggregation industrial standard, i.e., each data point is the average of measures over a period of 10 minutes (IEC, 2022). This data format is suitable for performance monitoring and eases data management and processing (Pandit, Astolfi, Hong, Infield & Santos, 2022).

As evidenced by Cheng & Chen (2022), the appropriate selection of informative features enhances the discriminative power of autoencoding models such as the VAE. In the present study, the selection of the SCADA measures was guided by the sensitivity analysis specific to each interest condition (Cheng & Chen, 2022) and general feature selection criteria (Liu *et al.*, 2021b; Pandit *et al.*, 2022).

Each abnormal condition has key features indicating the physical nature of the condition itself. For example, the main bearing temperature  $T_{BEA}$  ( $^{\circ}\text{C}$ ) is the most informative feature to analyze the BEA condition. Analogously, the gearbox oil temperature  $T_{GBX-OIL}$  ( $^{\circ}\text{C}$ ) is essential to analyze GBX and SWT; generator temperature  $T_{GEN}$  ( $^{\circ}\text{C}$ ) is essential to analyze GEN. The ICE condition can be characterized by the power curve, i.e., from the pair wind speed  $WS$  (m/s) and active power  $P$  (kW) (Guo & Infield, 2021).

Some of the available measures add little or no information to the characterization of the WT condition. Such a lack of informative power can be related to three reasons. First, some variables are highly correlated with already selected measures (Zeng *et al.*, 2022). For example, the battery box temperature is measured at three positions  $T_{BAX-BOX_i}, i \in \{1, 2, 3\}$ . The cross-correlation coefficient between each pair among these three measures is one; thus, only  $T_{BAX-BOX1}$  was retained to describe the battery box temperature. Second, the 10-minute average erases any significant information from measures varying at a very high frequency, such as the electrical frequency and voltage (both neglected in the model) (Beretta, Pelka, Cusidó & Lichtenstein, 2021b). Thirdly, some variables are too scarce, i.e., their time series present many missing or non-numerical entries (Martí-Puig, Blanco-M, Cárdenas, Cusidó & Solé-Casals, 2018). Such is

the case for the nacelle yaw position angle. Finally, it is worth mentioning that no vibratory or acoustic measures were available for the wind farm under analysis.

In light of the previous considerations, the present work uses the 13 key SCADA measures listed in Table 3.2. For each measure, the upper and lower bounds (LB and UB, respectively) were defined from the statistical analysis of the measures from all wind turbines. Such bounds have a twofold goal in pre-processing : first, filtering out physically incoherent values, i.e., values outside of the interval [LB, UB]; second, normalizing the measures into the [0, 1] interval with min-max normalization (Martí-Puig *et al.*, 2018).

Tableau 3.2 SCADA measures used as features with the respective lower (LB) and upper (UB) bounds

Measure	Symbol	Unit	LB	UB
Wind Speed	$WS$	m/s	0	31
Rotor Speed	$n_{ROTOR}$	rpm	0	18
Active Power	$P$	kW	0	2000
Ambient Temp.	$T_{AMB}$	°C	-25	45
Nacelle Temp.	$T_{NAC}$	°C	-20	70
Main Bearing Temp.	$T_{BEA}$	°C	-20	70
Gearbox Bearing Temp.	$T_{GBX-BEAR}$	°C	0	100
Gearbox Oil Temp.	$T_{GBX-OIL}$	°C	0	100
Generator Temp. Position 1	$T_{GEN1}$	°C	-10	140
Generator Temp. Position 2	$T_{GEN2}$	°C	-10	140
Generator Cooling Temp.	$T_{GEN-COOL}$	°C	-10	120
Pitch Axis Box Temp.	$T_{AX-BOX}$	°C	0	60
Battery Box Temp. Position 1	$T_{BAT-BOX1}$	°C	0	45

Besides the raw SCADA measures, the database includes SCADA log files and O&M reports. Both sources contain information on eventual underperformance root causes, degradation

symptoms, and failure patterns in specific components. One can exploit such metadata to select the abnormal conditions in a given wind farm. The SCADA log files indicate exceptions on the WT operation, while the O&M reports are multi-entry forms filled out by the O&M practitioners.

Section 3.5.1 describes the definition and labelling of the condition-specific datasets. Fig. 3.1 depicts the distribution of the datasets of interest in two plots.

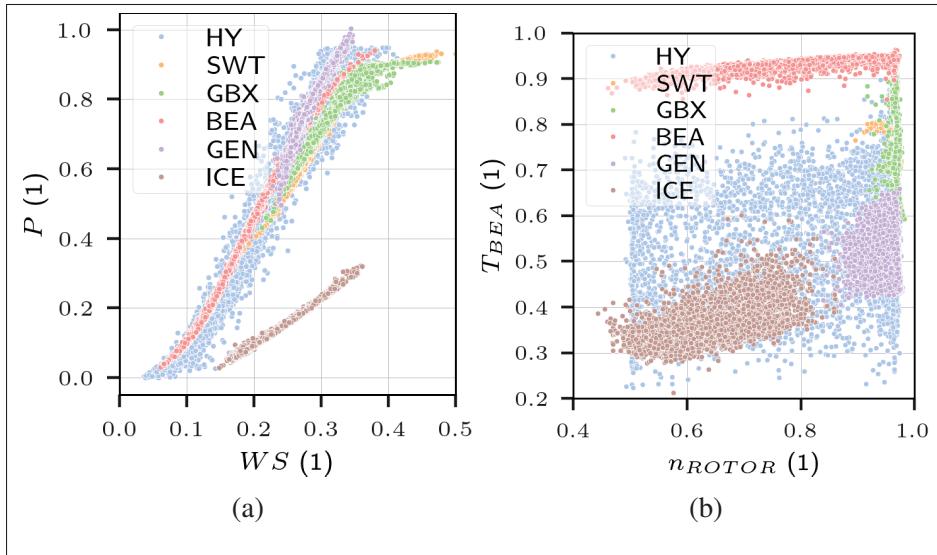


Figure 3.1 Distribution of the datasets of interest in (a) the normalized power curve and (b)  $T_{BEA}$  versus  $n_{ROTOR}$  plot

The superposition of clusters in Fig. 3.1(a) and 3.1(b) illustrates the difficulties in characterizing the WT conditions based on subspaces of the high-dimensional WT physical space. Rather than analyzing such a space, the approach proposed in the present work is based on a low-dimensional representation of the WT condition.

### 3.3 Background

A brief description of the VAE model in Section 3.3.1 is followed by the characterization of the VAE latent space for multiple-class databases in Section 3.3.2. Then, Section 3.3.3 reviews semi-supervised and supervised implementations of the VAE.

### 3.3.1 Variational Autoencoder

Kingma & Welling (2014) introduced the VAE as a generative model combining variational Bayesian and deep learning methods. We refer to Kingma *et al.* (2019) and Doersch (2016) for a comprehensive presentation of the VAE. A brief description of the VAE is given below.

Let  $\mathbf{x} = [x_1, \dots, x_{n_F}]^T \in \mathbb{R}^{n_F}$  be a vector describing the physical state of an arbitrary system. The VAE is a DNN model that builds an approximation for  $\mathbf{x}$ , denoted  $\hat{\mathbf{x}}$ , through three transformations, namely the encoder, the reparametrization trick, and the decoder. Fig. 3.2 illustrates the VAE architecture and highlights the loss function components  $\mathcal{L}_{RE}$  and  $\mathcal{L}_{KL}$ .

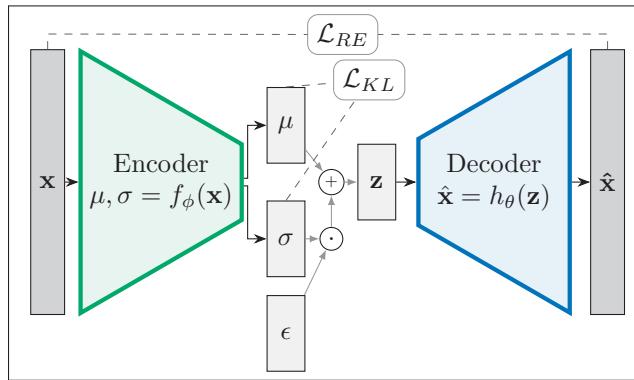


Figure 3.2 Schematic representation of the VAE model

The encoder is a DNN with parameters  $\phi$  that maps  $\mathbf{x}$  into the latent space mean  $\mu \in \mathbb{R}^{n_L}$  and standard deviation  $\sigma \in \mathbb{R}^{n_L}$ , as given by Eq. (3.1), where  $n_L < n_F$ .

$$f_\phi : \mathbf{x} \mapsto \{\mu, \sigma\}, \mathbb{R}^{n_F} \rightarrow \mathbb{R}^{n_L} \times \mathbb{R}^{n_L} \quad (3.1)$$

The reparametrization trick introduces a variational Bayesian approximation to the latent space (Doersch, 2016). It maps the  $\mu$  and  $\sigma$  into the latent variable  $\mathbf{z} \in \mathbb{R}^{n_L}$  according to Eq. (3.2), where  $\epsilon \sim \mathcal{N}(0, 1)$  is a  $n_L$ -dimension Gaussian vector with sample space  $\mathcal{E}$ , and  $\odot$  is the element-wise

product.

$$g : \{\mu, \sigma, \epsilon\} \mapsto \mathbf{z} = \mu + \sigma \bullet \epsilon, \mathbb{R}^{n_L} \times \mathbb{R}^{n_L} \times \mathcal{E} \rightarrow \mathbb{R}^{n_L} \quad (3.2)$$

Finally, the VAE decoder is a DNN mapping the latent space variable  $\mathbf{z}$  into the VAE output  $\hat{\mathbf{x}}$ , as given by Eq. (3.3), where  $\theta$  is the set of the decoder parameters.

$$h_\theta : \mathbf{z} \mapsto \hat{\mathbf{x}}, \mathbb{R}^{n_L} \rightarrow \mathbb{R}^{n_F} \quad (3.3)$$

Training the VAE involves minimizing the loss function  $\mathcal{L}_{VAE}$  with an algorithm such as the stochastic gradient descent. The VAE loss function is given by Eq. (3.4), where  $\mathcal{L}_{RE}$  is the reconstruction error,  $\mathcal{L}_{KL}$  is the KL divergence, and the coefficient  $\beta_{kl} > 0$  is set to prevent the KL-vanishing problem (Higgins *et al.*, 2016; Zemouri *et al.*, 2022).

$$\mathcal{L}_{VAE} = \mathcal{L}_{RE} + \beta_{kl} \mathcal{L}_{KL} \quad (3.4)$$

The reconstruction error  $\mathcal{L}_{RE}$  is given by Eq. (3.5) :

$$\mathcal{L}_{RE} = \frac{1}{n_F} \sum_{j=1}^{n_F} (x_j - \hat{x}_j)^2 \quad (3.5)$$

The  $\mathcal{L}_{KL}$  loss function measures the statistical distance between the latent variable distribution and the multivariate Gaussian distribution. Eq. (3.6) gives  $\mathcal{L}_{KL}$  as a function of  $\mu$  and  $\sigma$ .

$$\mathcal{L}_{KL} = \frac{1}{2} \sum_{j=1}^{n_L} (\sigma_j^2 + \mu_j^2 - \log \sigma_j^2 - 1) \quad (3.6)$$

Such training forces the VAE parameters to assume values so that (i) the encoder keeps essential information from the physical space and (ii) the decoder reconstructs a good approximation for the input features from the latent space variable. Moreover, the variational approximation

implies that (iii) the encoding of the training database projects points in the latent space that follow approximately a multivariate Gaussian distribution.

### 3.3.2 VAE Latent Space for a Multiple-Condition Database

Once the VAE is trained, the encoding of the training database projects its points into the latent space. Due to the variational approximation, datasets corresponding to a particular condition are encoded into a specific region in the latent space. The distribution of the encoded training points in the latent space depends on the characteristics of the training database and the  $\beta_{kl}$  coefficient. For instance, the encoding of a homogeneous database, i.e., whose points correspond to only one condition, results in a unique cluster of points in the latent space. A heterogeneous training database, on the contrary, projects into multiple clusters in the VAE latent space. In both cases, the set of all points together follows approximately the multivariate Gaussian distribution in the latent space. Setting a relatively large  $\beta_{kl}$  forces the latent space points to follow the Gaussian distribution.

The clusters corresponding to multiple datasets can be disjointed or entangled. Datasets sharing common patterns tend to project into superposed clusters, while very different behaviors would project into disentangled clusters. These cases are illustrated in Fig. 3.3 for a subset of the MNIST database (Deng, 2012). Notice that the clusters corresponding to the numbers 2, 3, and 8 are partially superposed.

Apropos, one can characterize a cluster by its distribution in the latent space. Let  $\Omega_k$  be a cluster with  $N_k$  points  $\{\mathbf{z}_1^{\Omega_k}, \dots, \mathbf{z}_{N_k}^{\Omega_k}\}$  in the  $n_L$ -dimension VAE latent space. The cluster's centroid  $\mathbf{C}^{\Omega_k}$  is the average position, with coordinates  $C_\ell^{\Omega_k}$ ,  $\ell \in \{1, \dots, n_L\}$ , given by Eq. (3.7).

$$C_\ell^{\Omega_k} = \frac{1}{N_k} \sum_{i=1}^{N_k} z_{i,\ell}^{\Omega_k} \quad (3.7)$$

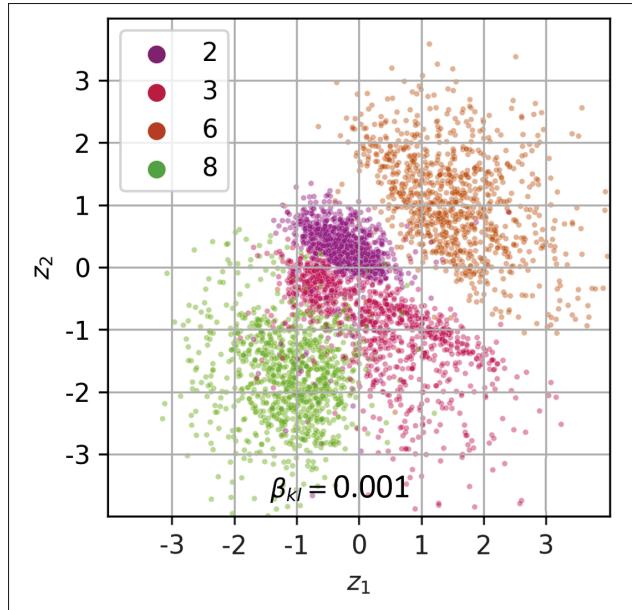


Figure 3.3 A 2-D latent space corresponding to the VAE trained on the subset {2,3,6,8} of the MNIST database with  $\beta_{kl} = 0.001$

### 3.3.3 Semi-Supervised and Supervised Variational Autoencoder

Latent space configurations with disentangled clusters better suit the purpose of using the latent space to characterize the original system. However, the VAE-based modelling of real-world cases with heterogeneous databases often implies a latent space with entangled clusters. Multiple works address techniques to disentangle clusters in the latent space (Kingma *et al.*, 2014; Cheng & Chen, 2022; Mathieu, Rainforth, Siddharth & Teh, 2019; Ezukwoke, Hoayek, Batton-Hubert & Boucher, 2022; Sohn *et al.*, 2015).

Cheng & Chen (2022) use the VAE to detect and diagnose abnormal behavior in ball bearings. The authors use sensitivity analysis to guide the selection of features, which leads to the disentanglement of clusters in the latent space and to the enhanced performance of the proposed VAE-based detection approach.

Another approach to increase the disentanglement of clusters in the VAE latent space and enhance the overall VAE capabilities is to include information on the classes of subsets of the database, leading to semi-supervised and supervised implementations of the VAE. Kingma *et al.* (2014) tackle the problem of classification when only a small share of the database is labelled. Sohn *et al.* (2015) propose the fully supervised model Conditional VAE that allows for specific condition data generation since its decoder takes the classes as input.

More recently, Proteau *et al.* (2020) introduced an approach based on the VAE model with two independent training steps. After training a classical VAE in the first step, a DNN model is defined as the combination of VAE encoder layers (including the reparametrization trick) and a classification neural network taking the latent space as input. The final model is a DNN inheriting the encoder's architecture that allows the disentanglement of the clusters in the latent space.

### **3.4 Proposed Condition Monitoring Approach**

The present work introduces a new supervised implementation of the VAE aiming at disentangling the multiple clusters in the latent space. This model is referred to as VAEC and is presented in Section 3.4.1. Ultimately, the VAEC latent space with disentangled clusters will serve the definition of both the HI and the visualization tool in sections 3.4.2 and 3.4.3, respectively.

#### **3.4.1 VAEC Model**

The VAEC consists of a VAE embedded with a classifier DNN, as schematized in Fig. 3.4. The input of the classifier DNN is the latent space variable  $\mathbf{z}$ , and its output is the vector  $\hat{\mathbf{y}}$  with dimension  $n_C$  (number of classes). The loss function components are highlighted in Fig. 3.4.

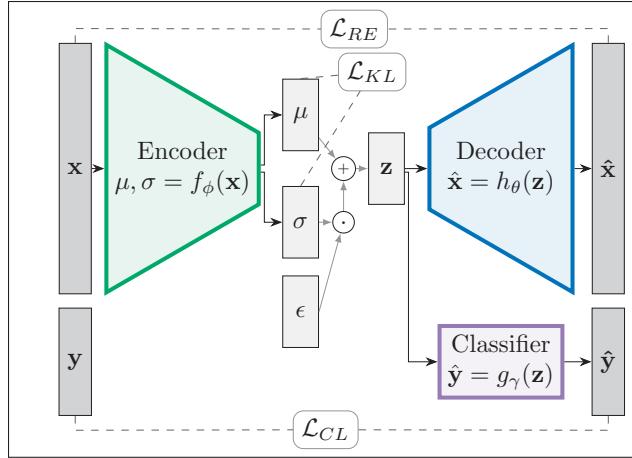


Figure 3.4 Schematic representation of the VAEC model

In the VAEC, the classifier DNN takes the latent space variable  $\mathbf{z} \in \mathbb{R}^{n_L}$  as input and its output  $\hat{\mathbf{y}} \in \mathbb{R}^{n_C}$  is defined by the Softmax activation function (Géron, 2019). The components  $\hat{y}_i, i \in \{1, \dots, n_C\}$ , indicate therefore the probability that the system's class is  $s_i$  among the set of classes  $\mathcal{S} = \{s_1, \dots, s_{n_C}\}$ . See Eq. (3.8).

$$g_\gamma : \mathbf{z} \mapsto \hat{\mathbf{y}}, \mathbb{R}^{n_L} \rightarrow \left\{ \hat{\mathbf{y}} \in [0, 1]^{n_C} : \sum_{i=1}^{n_C} \hat{y}_i = 1 \right\} \quad (3.8)$$

The classifier DNN is identified by minimizing the classification loss function  $\mathcal{L}_{CL}$ . A usual formulation for  $\mathcal{L}_{CL}$  is the cross-entropy function given by Eq. (3.9), where  $\mathbf{y} = \mathbf{e}_k \in \mathbb{R}^{n_C}$  results from the categorical one-hot-encoding transformation (Géron, 2022) corresponding to the set of labels  $\mathcal{S}$ , and  $\hat{\mathbf{y}}$  is the Softmax-shaped output of the classifier  $g_\gamma$ .

$$\mathcal{L}_{CL} = \mathbf{y} \cdot \log(\hat{\mathbf{y}}) + (\mathbf{1} - \mathbf{y}) \cdot \log(\mathbf{1} - \hat{\mathbf{y}}) \quad (3.9)$$

The VAEC loss function is given by Eq. (4.15). It combines  $\mathcal{L}_{RE}$  (Eq. (3.5)),  $\mathcal{L}_{KL}$  (Eq. (3.6)), and  $\mathcal{L}_{CL}$  (Eq. (3.9)). The weights  $\beta_{kl} \geq 0$  and  $\beta_{cl} \geq 0$  allow us to adjust the loss function

components. Setting  $\beta_{cl} = 0$  retrieves the classical VAE.

$$\mathcal{L}_{VAEC} = \mathcal{L}_{RE} + \beta_{kl} \mathcal{L}_{KL} + \beta_{cl} \mathcal{L}_{CL} \quad (3.10)$$

Fig. 3.5 depicts the VAEC latent space for the subset of the MNIST database considered previously.

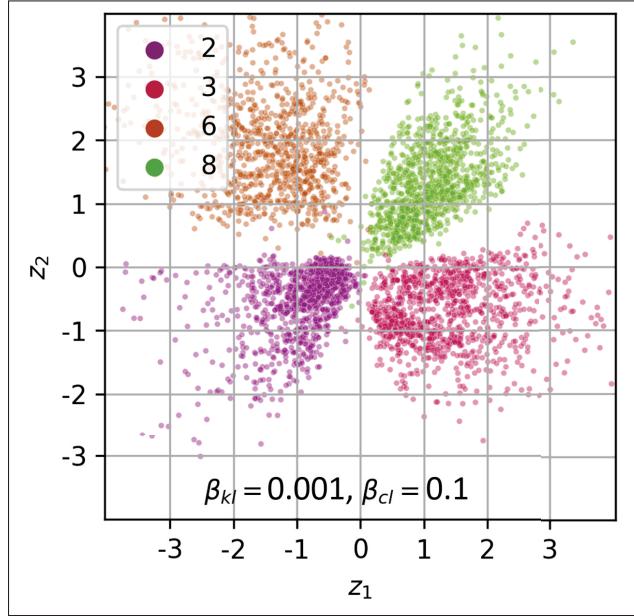


Figure 3.5 The 2-D latent space corresponding to the VAEC trained with the MNIST database with  $\beta_{kl} = 0.001$  and  $\beta_{cl} = 0.1$

It is worth noticing that the loss function coefficients  $\beta_{kl}$  and  $\beta_{cl}$  have different impacts on the latent space distribution. While the  $\beta_{kl}$  coefficient is mainly associated with the scattering of points in the latent space, the coefficient  $\beta_{cl}$  directly affects the clusters' separation. For instance, setting a relatively large  $\beta_{kl}$  value implies a latent space distribution closer to the multivariate Gaussian distribution. On the other hand, setting a large  $\beta_{cl}$  forces the VAEC training to distinguish the different WT conditions. The proposed approach is particularly suitable for databases with labelled conditions, as is the case of WTs characterized by SCADA measures and whose operating conditions can be characterized.

### 3.4.2 Proposed Health Indicator, Detection, and Diagnosis

Once the VAEC is trained on the WT condition database, its encoder projects the training database into the latent space. For a VAEC identification chosen as a reference, one can characterize the distribution of the cluster  $\Omega_{HY} \subset \mathbb{R}^{n_L}$  corresponding to the healthy dataset  $HY$ . Let  $n_{HY} \gg 1$  be the number of points belonging to  $\Omega_{HY}$ . The vectors of the coordinates of all points  $\mathbf{Z}_\ell^{HY} \in \mathbb{R}^{n_{HY}}$ ,  $\ell \in \{1, \dots, n_L\}$ , allow the estimation of the average position  $\mathbf{C}^{HY} \in \mathbb{R}^{n_L}$  and the covariance matrix  $S_{HY} \in \mathbb{R}^{n_L \times n_L}$ . The Mahalanobis distance between a point  $\mathbf{z} \in \mathbb{R}^{n_L}$  in the latent space and the  $\Omega_{HY}$  distribution is then given by Eq. (3.11).

$$d_M(\mathbf{z}) = \sqrt{(\mathbf{z} - \mathbf{C}^{HY})^T S_{HY}^{-1} (\mathbf{z} - \mathbf{C}^{HY})} \quad (3.11)$$

In the latent space, a data point corresponding to a degraded condition is encoded to a position far from the  $\Omega_{HY}$  cluster, thus implying a larger distance  $d_M(\mathbf{z})$ . The HI  $I_{Dm}$  is defined as the average of the Mahalanobis distances during the period  $\mathcal{T}_k$ , as given by Eq. (3.12), where  $n[\mathcal{T}_k]$  is the number of data points in  $\mathcal{T}_k$ .

$$I_{Dm}(\mathcal{T}_k) = \frac{1}{n[\mathcal{T}_k]} \sum_{t \in \mathcal{T}_k} d_M(\mathbf{z}(t)) \quad (3.12)$$

The EWMA control chart is used to detect trends in  $I_{Dm}$ . For the WT under analysis, data from operation in a healthy condition are used to estimate the reference statistics for  $I_{Dm}$ , particularly the average  $Z_M$  and the standard deviation  $s_M$ . The EWMA time series associated with the HI  $I_{Dm}$ ,  $EWMA_{Dm}$ , is then given by the initial condition  $EWMA_{Dm}(0) = Z_M$ , and the recursive relation in Eq. (3.13) for  $k \in \{1, 2, \dots\}$ , where  $\lambda \in [0, 1]$  is the EWMA parameter that attributes weight to the previous observations of the variable under analysis.

$$EWMA_{Dm}(k) = \lambda I_{Dm}(k) + (1 - \lambda) EWMA_{Dm}(k - 1) \quad (3.13)$$

The Upper Control Limit (UCL) is given by Eq. (3.14), where  $L$  is a parameter of the EWMA control chart.

$$UCL(i) = Z_M + L \cdot s_M \left( \frac{\lambda}{2 - \lambda} \right) [1 - (1 - \lambda)^{2i}] \quad (3.14)$$

The base detection criterion is given by Eq. (3.15).

$$EWMA Dm(k) > UCL(k) \quad (3.15)$$

In the present work, each subgroup  $\mathcal{T}_k$  covers one calendar day, which corresponds to up to 144 time steps. The EWMA coefficients are set as  $\lambda = 0.1$  and  $L = 3$ . Finally, an alarm is triggered when the base detection criterion is met in three consecutive time steps.

The settings mentioned above follow practical recommendations for the EWMA control chart on Gaussian-distributed variables and analysis on multiple case studies from the WT condition database. The Mahalanobis distance and the EWMA control chart are also exploited by Renström *et al.* (2020). Contrary to our proposition, the previous work applied the EWMA control chart directly on the Mahalanobis distance (the corresponding distribution is approximately a  $\chi_k$ , not Gaussian) and an exceptionally small  $\lambda$  (0.007).

The VAEC classifier has a twofold purpose in the proposed approach : first, it allows adjustment of the VAEC latent space ; second, it gives information on the diagnosis of the WT condition via the output  $\hat{\mathbf{y}}$ . The WT condition  $s_i \in \mathcal{S}$  is indeed given by  $\text{argmax}\{\hat{\mathbf{y}}\}$ . It is worth mentioning that the detection captures the point at which the projection of the WT in the latent space is distanced from the healthy condition cluster  $\Omega_{HY}$ . In such a case, the projection of the WT in the latent space might move closer to any of the abnormal condition clusters under analysis. The diagnosis of the transition to a new abnormal condition follows from both the classifier output and the visualization tool.

### 3.4.3 Visualization Tool

Setting the VAEC latent space dimension as two or three allows us to use this low-dimensional space as a visualization tool. The proposed visualization consists of two superposed layers. The first layer consists of the clusters resulting from the VAEC encoding of the training database. It is therefore fixed once a reference VAEC is adopted. The second layer projects the successive datasets  $\mathbf{x}_{t_k}^{SCADA}$  over the first layer. This projection is updated periodically, which allows visualization of the evolution of the WT condition in the map of conditions set by the first layer.

To improve the readability of the visualization tool for data covering larger periods, one can plot the centroids corresponding to the projection of datasets instead of individual data points. This choice can be adjusted to suit different periods of analysis and O&M requirements. A four-day time window is used in the present work. Additionally, a sequential colormap highlights the timeline in the visualization tool, with cyan dots at the beginning of the timeline and magenta dots for the latest data points. Finally, a gray dashed line connects the successive dots.

## 3.5 Methodology

The implementation of the proposed approach consists of two phases, namely, online and offline, as schematized in Fig. 3.6, where the wide gray arrows symbolize steps implemented once with information from multiple machines, and the black arrows indicate transformations specific to one WT and repeated periodically.

The offline phase is performed once and takes data from multiple machines of the wind farm assumed to be from the same model and to operate in similar conditions. On the other hand, the online phase is periodically fed with SCADA measures from one WT and gives an updated CM status for this specific machine. The building blocks comprising the online phase's pipeline are defined in the offline phase.

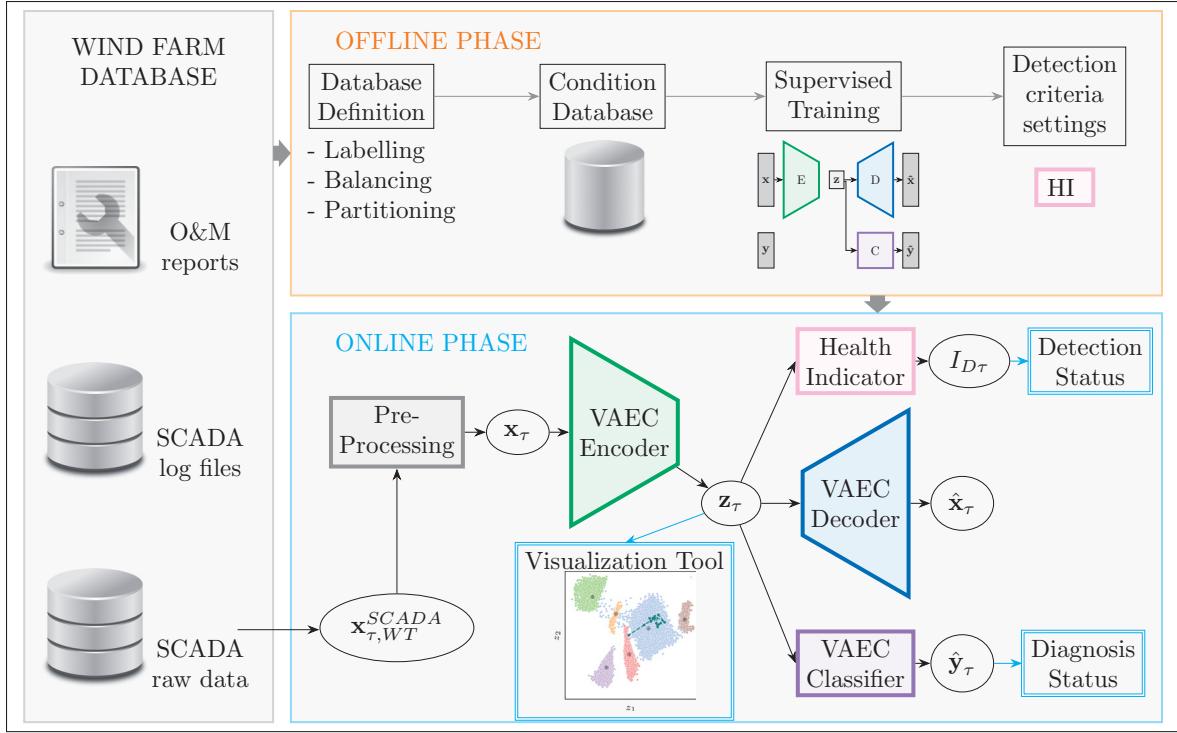


Figure 3.6 Flowchart identifying the phases of the proposed approach

The preparation of the multiple-condition labelled database comprises filtering and normalizing the SCADA data, labelling, balancing, and partitioning. These steps are discussed in Section 3.5.1 and 3.5.2. Section 3.5.3 describes the architecture, hyperparameters, and training of the VAEC.

### 3.5.1 Database Pre-Processing

The pre-processing of the database follows the industry practices for WT SCADA data, which includes filtering and normalization.

Measures from the SCADA system eventually present unlikely values (e.g., beyond physical limits) that can bias and distort the CM approach. Filters are therefore used to remove any physically incoherent values. Band-pass filters specific to each measure are set with the lower and upper limits from Table 3.2 (Oliveira-Filho *et al.*, 2022). For the database under analysis, data outside the limits in Table 3.2 correspond to less than 1% of all data points.

Moreover, the CM analysis considers only data corresponding to energy production. A second filtering step is therefore included to select data points verifying  $P[kW] > 0$  and  $n_{ROTOR}[rpm] > 0$ . After the two filtering steps, each measure is normalized to the  $[0, 1]$  interval for use in the DNN models. The min-max normalization technique (Patro & Sahu, 2015) uses the limits from Table 3.2.

### 3.5.2 Data Labelling, Balancing, and Partitioning

The task of dataset labelling uses three sources of information : SCADA raw measures, SCADA log files, and O&M reports. Combining these data and metadata allows for the definition of the datasets corresponding to the conditions listed in Table 3.1. To detect a changing operating condition early on, the data points selected to represent a given condition might exceed the set of data points with a reported SCADA exception. For a given condition, the three steps to define the dataset are the following :

- (i) Select a subset of the WT affected by the condition of interest. This step uses the SCADA log files and the O&M reports.
- (ii) Enumerate the degradation cases from the subset of WT defined in (i). The outcome of this step is a list of cases, each identified by the WT identifier, the starting instant, and the ending instant.
- (iii) Gather the data corresponding to the cases listed in (ii). The resulting dataset comprises data points from multiple wind turbines and is supposed to represent the overall condition of interest.

Fig. 3.7 illustrates step (ii) of the definition of the GBX dataset. The gearbox oil temperature  $T_{GBX-OIL}$  is plotted within an interval comprising the « gearbox oil overtemperature » SCADA alarm. The threshold for abnormal behavior is manually set considering multiple samples for the same condition, which leads to the definition of the extended dataset highlighted in Fig. 3.7. Time is indicated in the format YYYY-MM.

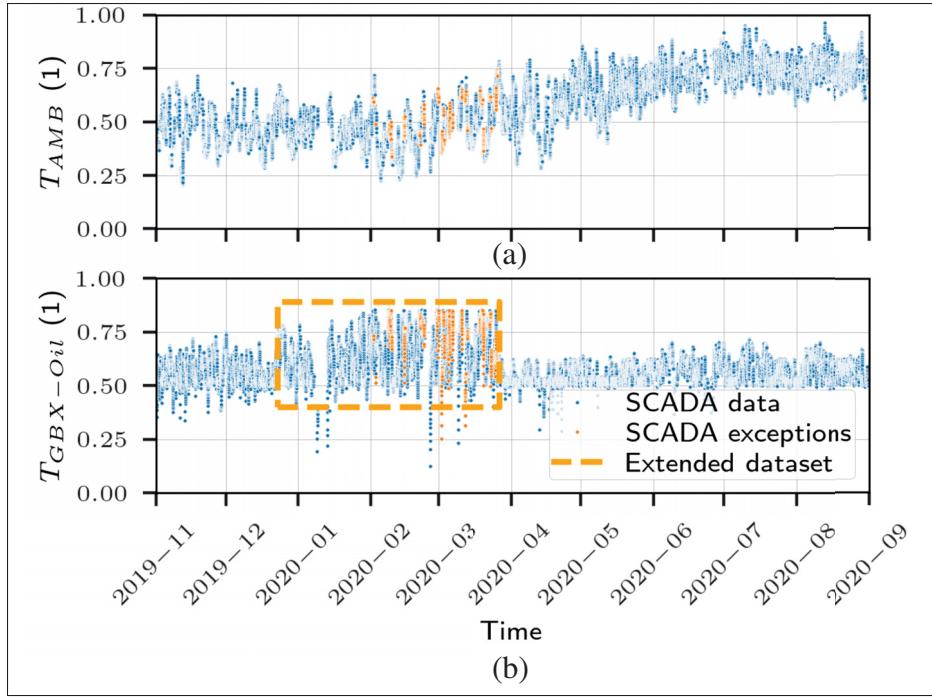


Figure 3.7 Illustration of the definition of the dataset « Gearbox oil overtemperature » considering time series for the normalized measures (a) ambient temperature  $T_{AMB}(1)$  and (b) gearbox oil temperature  $T_{GBX-Oil}(1)$

The datasets resulting from step (iii) have different numbers of points. Therefore, a data augmentation technique based on the VAE model is used to balance the datasets (Tanner & Wong, 1987; Chadebec *et al.*, 2022). Precisely, each homogeneous condition dataset is used to train a VAE model. Its latent space is the support to randomly generate points using the Gaussian distribution. Then, the VAE decoding of the latent space points generates the augmented dataset (Chadebec *et al.*, 2022). The target number of points for each dataset is  $n = 10000$ .

The final database is a collection of six datasets with  $n = 10000$  data points each. For the sake of training and evaluation, this database is partitioned into three databases : training (with 50% of all data points), validation (20%), and testing (30%).

### 3.5.3 VAEC Model : Architecture and Training

The proposed approach was implemented with Python (ver. 3.10). In particular, the implementation of the DNN models used TensorFlow (Abadi *et al.*, 2016) and the Keras API. The VAEC architecture and training hyperparameters are described below. These settings were chosen following sensitivity analysis with the training and testing databases.

- Dimensions : input space  $n_F = 13$ ; latent space  $n_L = 2$ ; classification output  $n_C = 6$ .
- Architecture :
  - Encoder : the encoder is a DNN with three hidden layers. The number of nodes per layer is, successively, 13 (input layer), 32, 16, 8, and 2 (output layer). The encoder input layer is set with the *ReLU* activation function, while *tanh* is used in the hidden layers. Moreover, a 10% dropout layer enters after the 32-node layer to prevent overfitting.
  - Decoder : the decoder is symmetric to the encoder (nodes per layer : 2, 8, 16, 32, and 13). The decoder output layer is set with the linear activation function. All the other decoder layers are set with the *tanh* activation function.
  - Classification DNN : the input of the classifier DNN is the latent space with dimension 2. The successive hidden layers have a decreasing number of nodes : 128, 64, 32, and 16. The *tanh* activation function is used in the input and the hidden layers. Finally, the classification output is a six-node layer using the *Softmax* activation function.
- Training : the Adam algorithm (Kingma & Ba, 2014) is used with learning rate 0.0001, clip value 0.3, number of epochs 1024, and batch size 128.

## 3.6 Results and Discussion

The reference VAEC model is presented in Section 3.6.1. Two case studies in Section 3.6.2 demonstrate the proposed approach.

### 3.6.1 Reference VAEC Model

Training the VAE with the wind turbine condition database described in Section 3.2 results in latent spaces with entangled clusters. This is illustrated in Fig. 3.8 for  $\beta_{kl} = 1$  and  $\beta_{kl} = 0.05$ .

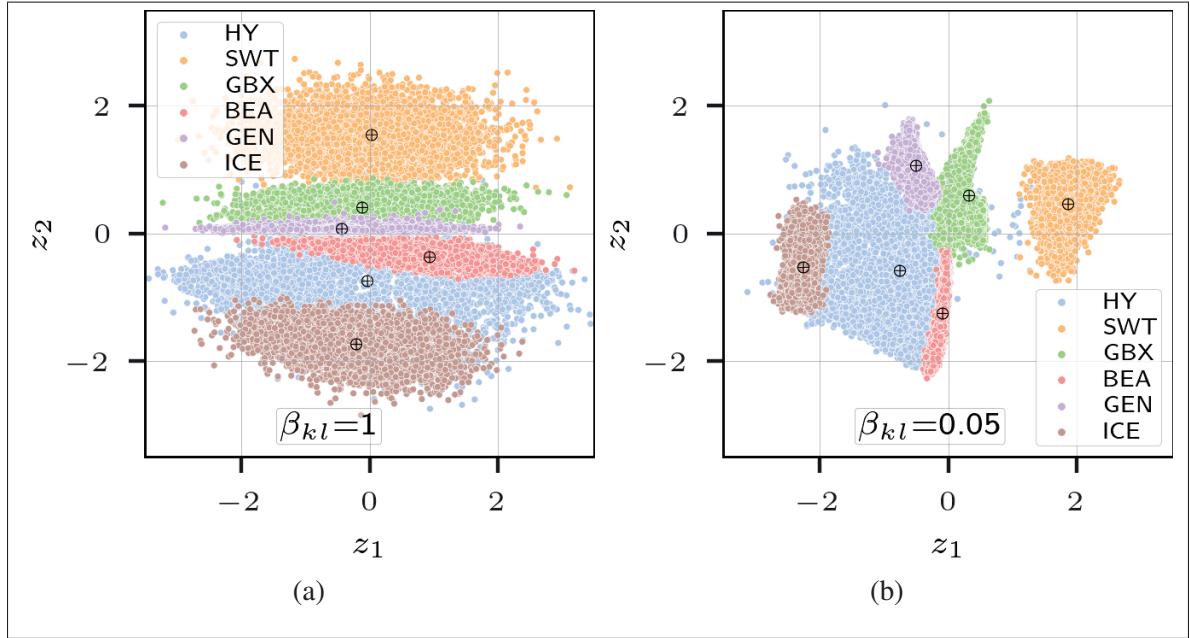


Figure 3.8 VAE latent space distribution for the labeled WT condition database from Table 3.1 using (a)  $\beta_{kl} = 1$  and (b)  $\beta_{kl} = 0.05$

Adjusting  $\beta_{kl}$  to decrease the weight of the KL loss disentangles the clusters to some extent, but not sufficiently for the purposes of defining the health indicator and an intuitive visualization tool. The VAEC was designed to disentangle the clusters corresponding to the labelled database of wind turbine conditions.

Due to the randomness of the VAEC training and the reparametrization trick, multiple training instances have different outcomes. In particular, the encoding of the training database has different projections into the latent space. Comparative analysis with multiple loss function coefficients led to the choice of the hyperparameters  $\beta_{kl} = 0.05$  and  $\beta_{cl} = 10$ , which gives a classification confusion matrix with accuracy higher than 98% for multiple training instances, and a latent space with overall disentangled clusters.

Fig. 3.9(a) depicts the VAEC-encoding projection and confusion matrix for one specific training of the VAEC model with the retained loss function coefficients —  $\beta_{kl} = 0.05$  and  $\beta_{cl} = 10$ . The corresponding VAEC model (architecture and identified parameters) is adopted as the reference for the online CM approach.

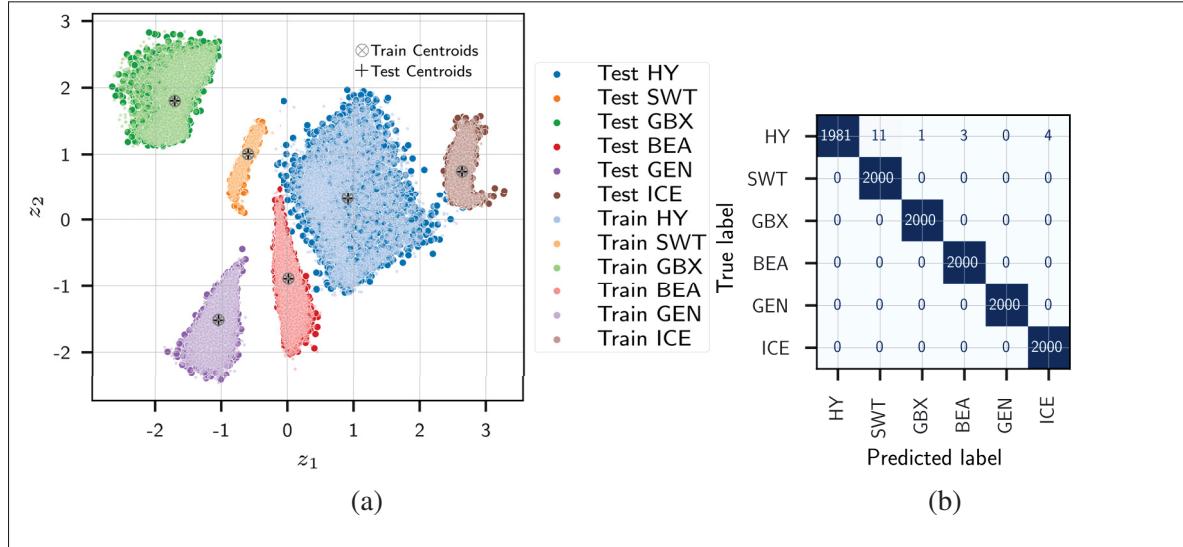


Figure 3.9 VAEC latent space distribution for the labeled wind turbine condition database from Table 3.1 with  $\beta_{kl} = 0.05$  and  $\beta_{cl} = 10$  : (a) encoding of train and test databases and (b) classifier confusion matrix for the test database

Notice that the VAEC encoding of the test datasets occupies virtually the same regions as the corresponding training datasets in Fig. 3.9(a). The encoding of the training database defines the visualization tool's static layer. The VAEC classifier has accuracy close to 100% for the training instance above, as depicted in Fig. 3.9(b). Such high performance can be related to the quality of the semi-manual labelling of the datasets. It also supports the choice of the latent variable  $\mathbf{z}$  as the input for the classifier in the VAEC model.

### 3.6.2 Case Studies

Two case studies demonstrate the proposed approach : Section 3.6.2.2 analyzes the case of a main bearing degradation until failure, and Section 3.6.2.1 presents the impact of a severe cold wave on the WT operation.

#### 3.6.2.1 Case Study I : Main Bearing Degradation

Case Study I refers to the degradation of the main bearing of the machine  $WT_A$  within the period [1 May 2020, 1 August 2020]. This case is particularly suitable to demonstrate the proposed approach given that it starts at the healthy condition and then degrades progressively until its failure and shutdown. The machine  $WT_A$  was kept shut down for more than a month twice within 2020 : first, after the shut down at  $t_{ShutDown1} = 1$  March 2020 ; then, months later, after the shut down at  $t_{ShutDown2} = 10$  August 2020. The available data suggest that a provisory maintenance intervention occurred in March, and a second one was performed in August after the main bearing failure. Such a chronology of O&M interventions is related to the weather conditions at the wind farm location. Indeed, historical data show that the windiest months were April, May, and June. August, on the contrary, had the lowest average wind speed.

The reference VAEC model allows the projection of the data points from Case Study I, resulting in the visualization tool depicted in Fig. 3.10. In this figure, cyan-coloured markers correspond to the beginning of the timeline, and magenta-coloured markers toward the end of it.

In practice, the visualization tool might be updated periodically, with the inclusion of new points in the trajectory representing the wind turbine condition. Fig. 3.10 can be interpreted as a snapshot of the visualization tool at  $t = 1$  August 2020. It shows that the WT was initially in the healthy cluster (as the cyan markers superpose the HY cluster) and then clearly shifted to the main bearing overtemperature (as the magenta markers superpose the BEA cluster).

The detection follows from the HI  $I_{Dm}$  and the EWMA control chart, as introduced in Section 3.4.2. Fig. 3.11(a) depicts  $I_{Dm}$  and  $EWMA_{Dm}$ , where time is indicated in the format YYYY-MM-DD.

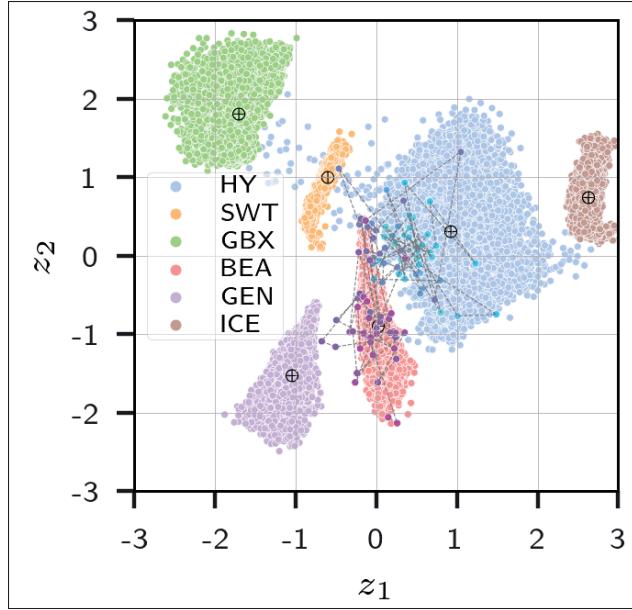


Figure 3.10 Visualization tool for Case Study I

These time series lead to an alarm at  $t_D = 15$  June 2020. This date is 11 days before the SCADA alarm at  $t_S = 26$  June 2020 and one week before the detection by the regression model residue-based approach proposed in (Cambron *et al.*, 2017). The latter method performs the main bearing degradation exclusively and leads to detection at  $t_{Do2} = 21$  June 2020. The same period [1 October 2019, 15 December 2019] is used as the reference for the healthy condition in both estimations.

The diagnosis is provided by the classifier output  $\hat{y}$  depicted in Fig. 3.11(b). Each vertical line corresponds to a 10-min time step. HY is the most probable condition at the beginning of the period, with  $\hat{y}_{HY} = 1$  most of the time. After 15 June 2020, however, the most probable condition becomes the main bearing overtemperature (BEA). There is some dispersion on  $\hat{y}$ , the classifier eventually indicating other overheating conditions such as GEN and STW. The authors judge that such dispersion partially reflects the evolution of the WT's condition over time. Ultimately, one might define the diagnosis status by setting adequate post-processing on  $\hat{y}$ . The definition of the diagnosis status is left for future work.

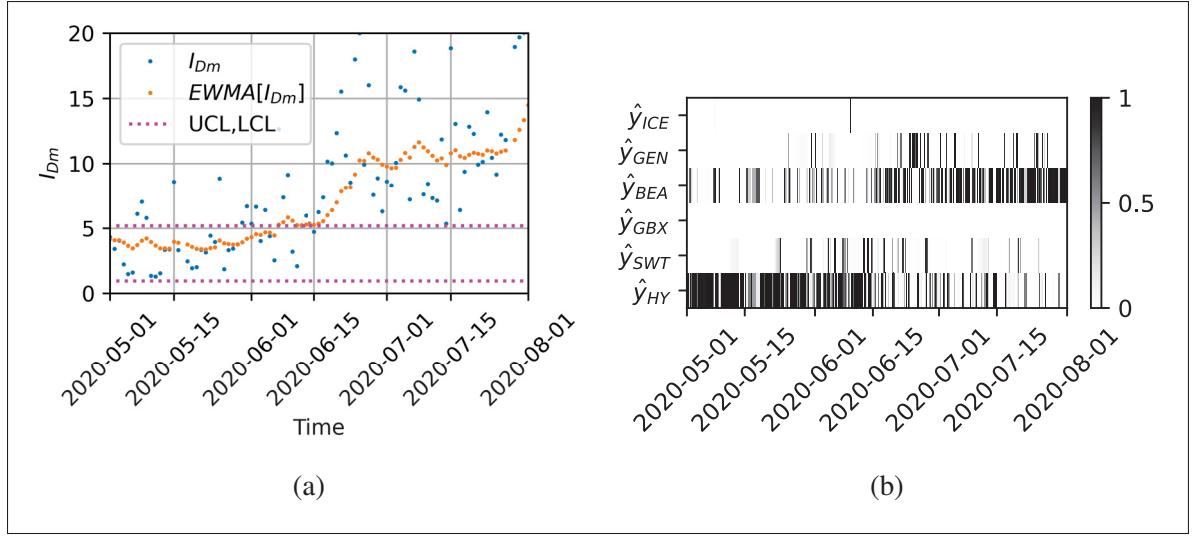


Figure 3.11 Case Study I : (a) detection and (b) diagnosis

The diagnosis in the proposed approach is based on the classifier DNN that constitutes the VAEC model. The confusion matrix from Fig. 3.9(b) evidences that the VAEC properly categorizes among selected WT conditions, therefore outperforming the diagnosis based only on the unsupervised VAE model (Roelofs *et al.*, 2021). The VAEC model is simpler than both AVAE\_SDL (Liu *et al.*, 2021b) and CVAE-GAN (Zhang *et al.*, 2022). A strict comparison of the performance of the three models is a difficult task since they use different types of inputs. For instance, the diagnosis from (Zhang *et al.*, 2022) relies on vibration data unavailable in the database under analysis.

### 3.6.2.2 Case Study II : Impact of a Cold Wave

This case study analyzes the operation of the machine  $WT_B$  under icing conditions observed during the 2021 cold wave in North America (Doss-Gollin, Farnham, Lall & Modi, 2021). The ambient temperature measured by the  $WT_B$ 's SCADA system reached values as low as  $T_{AMB} - 16.5^{\circ}\text{C}$  in February 2021. The blades of the WT under analysis are not equipped with anti-icing systems. In case of exceptional icing conditions, careful condition monitoring is required to detect and diagnose ice accretion on blades, which should trigger protocols for curtailment or even shutdown (Veers *et al.*, 2021).

Fig. 3.12 depicts the visualization tool for Case Study II, i.e., data points from the machine  $WT_B$  covering the period of interest [1 December 2020, 4 March 2021]. Such a projection uses the reference VAEC model defined in Section 3.6.1.

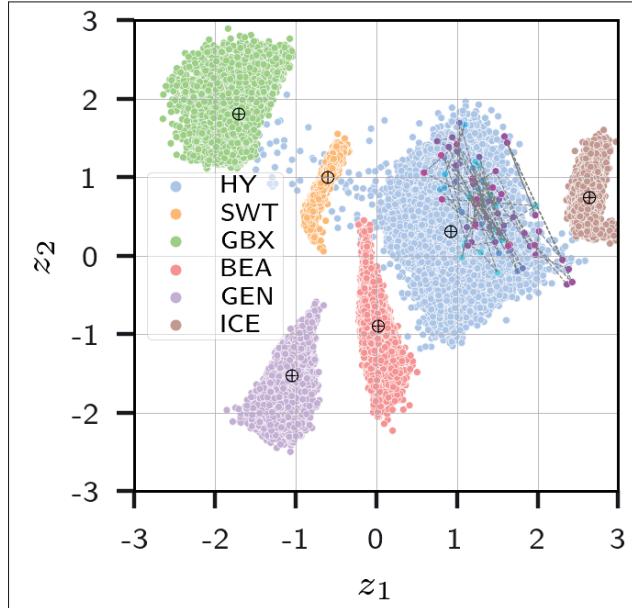


Figure 3.12 Visualization tool for Case Study II

Fig. 3.12 reveals a shift in the WT condition toward the ICE cluster. It is worth noticing that the trajectory in the latent space remains mostly inside the HY cluster, indicating that the ice accretion observed during the period under analysis was milder than the cases in the ICE training dataset. The power curve confirms this since the Case Study II data points remain closer to the HY cluster than the ICE cluster. More severe ice accretion is expected to shift the projection into the ICE cluster.

The proposed CM approach captures the  $WT_B$  changing condition under the 2021 cold wave. Indeed, as depicted in Fig. 3.13(a), the period of the cold wave corresponds to an increased value for  $I_{Dm}$ , with an alarm triggered at  $t_D = 15$  February 2021. The EWMA control chart used the period [5 December 2020, 5 January 2021] as a reference.

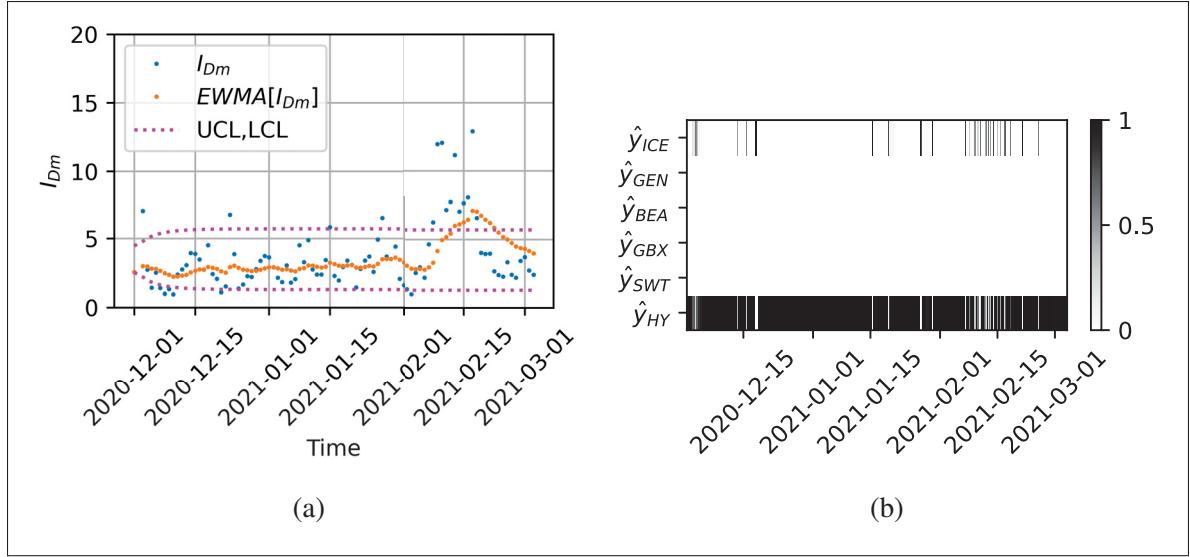


Figure 3.13 Case Study II : (a) detection and (b) diagnosis

Fig. 3.13(b) depicts the classifier output  $\hat{y}$ . Here,  $\hat{y}_{HY} = 1$  most of the time, except for a few time steps when  $\hat{y}_{ICE} = 1$ . The comparison with competing approaches is left for future work.

From the O&M standpoint, the actions to take in the scenario of ice accretion on blades are limited. In extreme cases, curtailment or shutdown might be necessary to prevent overloading of the rotor blades. After such an event, damage detection specific to the wind turbine blades would be recommended to assess the health condition (Márquez & Chacón, 2020; Kaewniam, Cao, Alkayem, Li & Manoach, 2022).

### 3.7 Summary and Conclusions

The present work introduced a new CM approach allowing for the early detection and diagnosis of abnormal conditions in WTs. The proposed approach includes a visualization tool for enhanced interpretability.

A supervised implementation of the VAE model was introduced to project the multiple-condition SCADA system into a 2-D disentangled representation space. This 2-D representation is a built-in visualization tool for the AI model. Furthermore, the low-dimensional representation

is representative of the dynamics of the physical measures, and it led to the definition of the proposed HI, the respective alarm criteria, and the classifier giving diagnosis information.

It was shown that each condition in the physical space was VAEC-encoded into a specific region in the latent space. In such a space, the evolution of the WT condition is expressed as a trajectory in a 2-D space. The proposed  $I_{Dm}$  uses the Mahalanobis distance to measure the distance between data points and the healthy cluster distribution in the latent space. The EWMA control chart allowed for the detection of changing trends in the HI time series.

Two case studies pertinently demonstrated the potential of the proposed approach in detecting, diagnosing, and visually representing abnormal conditions in WTs. The proposed alarm criteria led to satisfactory anticipation of the SCADA alarms. In particular,  $I_{Dm}$  triggered an alarm for the main bearing overtemperature 11 days earlier than the best-performing competing method. The two case studies illustrated the pertinence of the visualization tool. In practice, the visualization tool would be updated periodically in the online CM, providing a visual representation of any trends in the WT condition. Such a tool enhances the interpretability of the outcomes, therefore easing its use by O&M practitioners.

It is worth mentioning that the supervised training of the VAEC implies the need for labelled datasets. Such a task is time-consuming and costly. Fortunately, once the offline phase is completed for a subset of WTs, the online CM is inexpensive, and its parameters can be adjusted according to the in situ experience. Further research might investigate alternatives to the VAEC model, eventually a semi-supervised VAE or methods to disentangle the (unsupervised) VAE latent space. The proposed visualization tool is an advantage compared to black-box models and establishes new examples for the literature on interpretable AI. Nevertheless, metrics to evaluate the interpretability remain to be established. A future investigation should evaluate the acceptability of the proposed visualization tool among O&M practitioners. Finally, the industrial implementation of the proposed approach would require evaluating the proposed approach within an extensive selection of case studies and WT models.

**Author contributions :** Conceptualization, A.O-F., R.Z., P.C., and A.T.; methodology, A.O-F., R.Z., and A.T.; software, A.O-F., R.Z., and P.C.; validation, A.O-F., R.Z., P.C., and A.T.; formal analysis, A.O-F. and R.Z.; investigation, A.O-F.; resources, P.C. and A.T.; data curation, A.O-F. and P.C.; writing — original draft preparation, A.O-F.; writing — review and editing, A.O-F., R.Z., P.C., and A.T.; visualization, A.O-F.; supervision, R.Z., P.C., and A.T.; project administration, P.C. and A.T.; funding acquisition, P.C. and A.T. All authors have read and agreed to the published version of the manuscript.

**Funding :** This work was supported by Mitacs through the grants Mitacs Globalink Graduate (grant number IT24180-FR62006) and Mitacs Acceleration (grant number IT22958-FR60047).

**Data availability :** Restrictions apply to the availability of these data. Data were obtained from Power Factors. **Acknowledgments :** The authors acknowledge Power Factors for providing the database used in the present study. **Conflicts of interest :** The authors declare no competing financial interests or personal relationships that could influence the present work.



## CHAPITRE 4

### SYSTEM CONDITION MONITORING BASED ON A STANDARDIZED LATENT SPACE AND THE NATAF TRANSFORM

Adaiton Oliveira-Filho<sup>1</sup>, Ryad Zemouri<sup>2</sup>, Francis Pelletier<sup>3</sup>, Antoine Tahan<sup>1</sup>

<sup>1</sup> Department of Mechanical Engineering, École de Technologie Supérieure, 1100 Rue Notre Dame O, Montreal, QC H3C 1K3, Canada;

<sup>2</sup> Research Center of Hydro-Québec, 1800 Bd Lionel-Boulet, Varennes, QC J3X 1S1, Canada;

<sup>3</sup> Power Factors, 7005 Boulevard Taschereau, Brossard, QC J4Z 1A7, Canada.

Article publié dans « IEEE Access Reliability Society Section » le 27 février 2024.

**Abstract :** This work introduces a new condition monitoring approach for complex systems based on a standardized latent space representation. Latent variable models such as the variational autoencoders are widely used to analyze systems described by a high-dimensional physical space. The encoding of such space defines a low-dimensional and physically representative latent space. Of note, however, the latent space obtained for complex systems operating under multiple conditions is often difficult to exploit in defining an efficient Health Index, thanks to the non-deterministic and hyperparameter-dependent nature of the latent space. In addition, the distribution of the healthy cluster is not known a priori. The original contribution of this paper is to use the Nataf isoprobabilistic transform to map the latent space into a standardized space. This normalizes the spatial structure of the latent space and relaxes the model's sensitivity to hyperparameters during the learning process. Moreover, the characterization of the healthy condition in the standard Nataf space leads to the definition of two complementary health indices suitable for complex systems. An implementation in two case studies demonstrates the potential of the proposed approach. First, the approach was successfully applied within NASA's Commercial Modular Aero-Propulsion System Simulation dataset. The second case study consisted in analyzing multiple degradation in operating wind turbines. Encouraging results emerge from both case studies, with critical conditions being detected significantly earlier than in competing approaches. The proposed approach can be generalized to complex systems equipped with multiple sensors, and overcomes difficulties related to latent space analysis of multiple condition systems.

**Keywords :** Condition monitoring, early detection, latent space modelling, Nataf transform, variational autoencoder

#### 4.1 Introduction

Modern engineering systems are increasingly complex and are expected to conform to rising standards of efficiency and reliability (Breneman, Sahay & Lewis, 2022). These challenging trends are well illustrated by the technological evolution of aeronautical systems, energy conversion systems such as WTs, and large industrial machines, among others (Smil, 2007, 2018; Herbert, Iniyan, Sreevalsan & Rajapandian, 2007). The costs and strategic importance of these assets justify the need for advanced CM approaches. Such approaches aim at continuously monitoring the condition of assets, which in turn allows for optimized O&M planning and enhanced reliability, in addition to providing economic benefits. Modern engineering systems are equipped with a large variety of sensors. The measures from such sensors provide a high-dimensional multi-physics description of the condition of these systems. The ever-increasing databases resulting from modern systems create new opportunities for CM. Data-driven approaches based on artificial intelligence models such as DNNs receive a lot of attention from industry and academia (Azimi, Eslamlou & Pekcan, 2020; Niu *et al.*, 2017).

Latent space representations are low-dimensional projections of high-dimensional physical spaces achieved through an appropriate inference function. The VAE model (Kingma & Welling, 2014) is probably the most popular LVM combining artificial neural networks and Bayesian inference methods. Once this generative model is trained, the encoder allows to project the input physical space into a low-dimensional Latent Variable (LV) space. Most importantly, the latent space reveals relations between data points that are usually not evident in the original high-dimensional physical space. Due to these capabilities, the VAE model has proven results in a wide range of applications. Furthermore, multiple variations of the VAE model have been introduced to deal with specific data and model characteristics (Kingma *et al.*, 2014; Sohn *et al.*, 2015; Zhu *et al.*, 2020; Proteau *et al.*, 2020; Zemouri *et al.*, 2022).

The case of systems operating under multiple distinct conditions is of particular interest for latent space representations. Indeed, variational encoding can isolate different operating conditions, and will ultimately reveal the relations existing between these conditions (Roelofs *et al.*, 2021; Zhang *et al.*, 2022; Oliveira-Filho *et al.*, 2023). Nevertheless, LVs corresponding to complex multiple condition systems are unsuitable for robust CM models due to several restrictions. First, the latent space representation of complex multiple condition systems is often intricate and non-deterministic. Indeed, the spatial representation of LVs is very sensitive to the model's hyperparameters and changes randomly for independent training instances. Finally, the distribution of the healthy cluster is not known a priori.

Variations of the classical unsupervised VAE model in the literature partially address the limitations of the classical VAE in analyzing complex systems (Tschannen *et al.*, 2018). In particular, supervised implementations of the VAE model exploit labels such as binary classification (healthy or abnormal condition), multiple-class categorization (healthy condition plus multiple abnormal conditions), or regression (condition indicated by a scalar) (Kingma *et al.*, 2014; Sohn *et al.*, 2015; Proteau *et al.*, 2020). In (Oliveira-Filho *et al.*, 2023), the authors show that the embedding of the VAE model with a classification DNN allows disentangling clusters in the latent space. In (Costa & Sánchez, 2022), the VAE is embedded with a regression DNN. These supervised learning models allow for disentangled clusters in the LV representation, but the latent space still varies between different instances of training.

The present paper aims to define a robust detection approach for complex systems, and to that end, introduces a new framework to achieve a latent space representation for high-dimensional complex engineering systems. The solution investigated herein consists in combining the LVs obtained by the VAE with the Nataf Transform (NT) introduced by (Nataf, 1962). The NT has been widely used among several reliability applications, such as in (Zhao, Liao & Dong, 2021a; Chen, Zheng, Zhang & Jia, 2021; Valamanesh, Myers & Arwade, 2015). The features of the complex system are then projected from the original and intricate latent space into the standard Nataf space. The latter representation overcomes the limitations of classical latent space representations, which allows to define a robust HI.

The following are the original contributions of the present paper :

- The NT is used to map an intricate latent space into the standard Nataf space. It is shown that the standard Nataf space overcomes the limitations of VAE-based latent space representations of complex multiple condition systems.
- A pair of complementary HI based on the standard Nataf space are introduced. The performance of the detection using the proposed HIs is demonstrated within two application case studies.
- This work introduces two new cases supporting the use of latent spaces as built-in visualization tools to enhance the interpretability of DNN models.

The remainder of this paper is organized as follows : Section 4.2 reviews latent space representations and anomaly detection based on such spaces. Section 4.3 describes the Nataf Transform. The proposed approach is introduced in Section 4.4. Two case studies demonstrate the proposed approach : the degradation of engines from the Commercial Modular Aero-Propulsion System Simulation (C-MAPSS) FD001 dataset, in Section 4.5, and the degradation of WTs from an operating North American wind farm, in Section 4.6. Section 4.7 summarizes and discusses the results from the case studies. Finally, Section 4.8 concludes the paper.

## 4.2 Problem formulation

### 4.2.1 Latent variable models

Let  $\mathbb{X} = \{\mathbf{x}^{(i)}\}_{i=1}^{N_X}$  be a dataset of  $N_X$  observed variables collected from the same system  $\mathcal{S}$ , whose unchanging underlying true distribution  $p^*(\mathbf{x})$  is unknown. The observations  $\mathbf{x}$  are assumed to be independently and identically distributed (i.i.d.) (Kingma, 2017), and can be considered as random samples obtained from the unknown underlying process  $\mathbf{x} \sim p^*(\mathbf{x})$ . The objective of LVM is to describe the data space distribution through a set of unobservable variables  $\mathbb{Z} = \{\mathbf{z}^{(i)}\}_{i=1}^N$  whose prior distribution  $p(\mathbf{z})$  is assumed to be known (Kong, Jiang, Zhang, Yuan & Ge, 2022; Kingma, 2017). This latent space or manifold has no physical meaning, but it is very suitable for revealing and disentangling the main relevant features from

the entangled space of data  $\mathbb{X}$ . An important condition for this feature extraction process and disentanglement is that the latent space must have a lower dimension than the original space, i.e.,  $\dim(\mathbb{Z}) = N < N_X = \dim(\mathbb{X})$ .

The objective of the LVMs is to find the posterior probability distribution function  $p(\mathbf{x})$  that gives the best approximation of the true distribution of the data  $p(\mathbf{x}) \approx p^*(\mathbf{x})$ . The posterior data distribution  $p(\mathbf{x})$  is then given through the conditional generative distribution  $p_\theta(\mathbf{x}|\mathbf{z})$  by  $p(\mathbf{x}) = \int p_\theta(\mathbf{x}|\mathbf{z}) p(\mathbf{z}) d\mathbf{z}$ , where  $p(\mathbf{z})$  is not conditioned on any observations, and is called the *prior distribution* over  $\mathbf{z}$ . The latent posterior distribution  $p_\phi(\mathbf{z}|\mathbf{x})$  can be obtained using the Bayes theorem for model inference through  $p_\phi(\mathbf{z}|\mathbf{x}) = p_\theta(\mathbf{x}|\mathbf{z}) p(\mathbf{z}) / p(\mathbf{x})$ . To this end, two parametric functions  $f_\phi$  and  $g_\theta$  are defined to sample  $\mathbb{X}$  to the latent space  $\mathbb{Z}$ , and conversely from  $\mathbb{Z}$  to  $\mathbb{X}$ . The inference function  $f_\phi$ , called the encoder, is used to map the data space to the latent space  $\mathbf{z} = f_\phi(\mathbf{x})$  and is employed to parameterize the inference distribution  $p_\phi(\mathbf{z}|\mathbf{x})$ . The mapping of the data space from the latent space is obtained by the generative function  $\mathbf{x} = g_\theta(\mathbf{z})$ , called the decoder, which is used to parameterize the generative distribution  $p_\theta(\mathbf{x}|\mathbf{z})$ .

The key idea of this process is to force the latent prior distribution to follow a known distribution such as the Gaussian distribution  $p(\mathbf{z}) \approx \mathcal{N}(\mathbf{z}; \mathbf{0}, \mathbf{I})$ . The latent Kullback-Liebler divergence loss is used to regularize the inference function in order to enforce the encoding data into the prior Gaussian latent space  $D_{KL}(p_\phi(\mathbf{z}|\mathbf{x}) \parallel p(\mathbf{z}))$ . Then, the mapping of the data space obtained by the generative function from the known prior distribution is forced to follow the true data distribution  $p^*(\mathbf{x})$ . Since the latter is unknown,  $p^*(\mathbf{x})$  can explicitly be estimated by forcing the decoder to reconstruct the data  $\tilde{\mathbf{x}} = g_\theta(f_\phi(\mathbf{x}))$ . A data reconstruction loss, such as the  $L_2$  norm or the mean-squared error  $\mathcal{L}_{\theta,\phi} = \frac{1}{2} \|\mathbf{x} - \tilde{\mathbf{x}}\|_2^2$ , is then used to guide this reconstruction process.

#### 4.2.2 Latent variable model for fault detection

It is important to note that when the two parametric functions ( $g_\theta, f_\phi$ ) are learned on a training dataset  $\mathbb{X}^{train}$  and the hyperparameters  $(\theta, \phi)$  are set, the posterior latent distribution obtained by mapping a new data sample  $\mathbb{X}^{new}$  will belong to the prior manifold  $p(\mathbf{z})$  even if

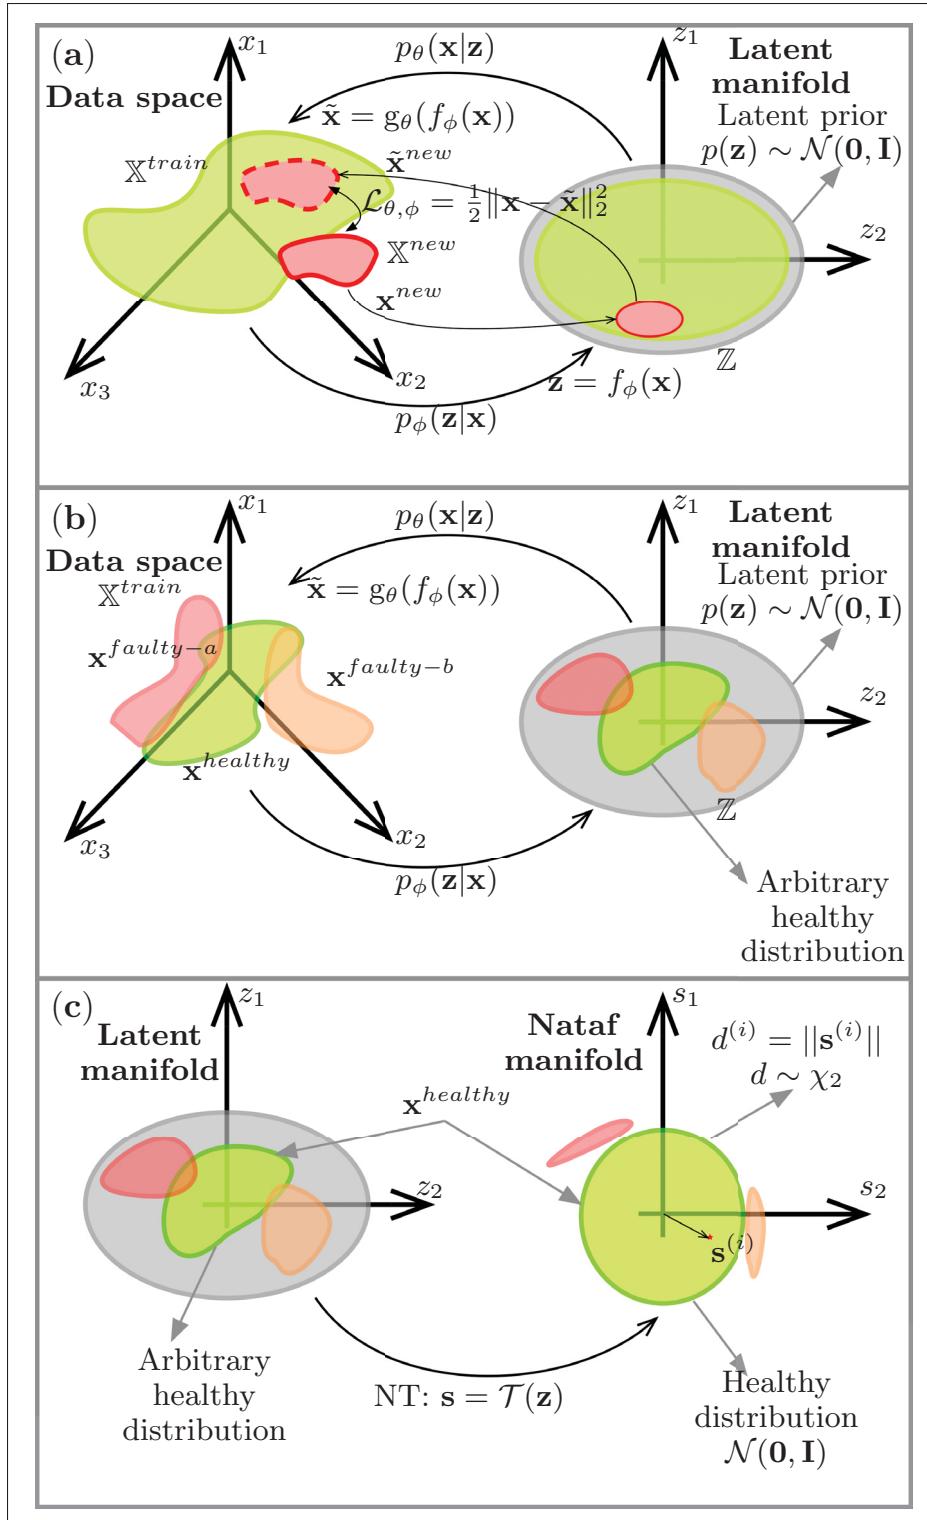


Figure 4.1 Applications of latent variable models : (a) the reconstruction process as a suitable HI, (b) training datasets include healthy and faulty samples, and (c) the proposed Nataf inference process is defined with respect to healthy samples

$p(\mathbf{x}^{new}) \not\approx p(\mathbf{x}^{train})$ . The reconstruction data  $\tilde{\mathbf{x}}^{new} = g_\theta(f_\phi(\mathbf{x}^{new}))$  obtained by both transition functions will have a posterior probability data distribution that somewhat approximates the training probability distribution  $p(\tilde{\mathbf{x}}^{new}) \approx p(\mathbf{x}^{train})$ . See Fig. 4.1(a). This reconstruction process is very suitable for fault detection if the LVMs learn the mapping of the healthy probability distribution only.

For instance, let  $p(\mathbf{x}^{healthy})$  be the healthy data distribution and  $p(\mathbf{x}^{faulty})$  the faulty distribution for a given anomaly such as  $p(\mathbf{x}^{healthy}) \not\approx p(\mathbf{x}^{faulty})$ . If the LVM has learned to map only the healthy data space  $\tilde{\mathbf{x}}^{healthy} \sim p(\mathbf{x}^{healthy})$ , the reconstruction process obtained for any faulty data will give  $\tilde{\mathbf{x}}^{faulty} \sim p(\mathbf{x}^{healthy})$ . The divergence between the original data distribution  $p(\mathbf{x})$  and the reconstructed data distribution  $p(\tilde{\mathbf{x}})$  is then used as a suitable HI  $HI = \mathcal{L}(\mathbf{x}, \tilde{\mathbf{x}})$ . This concept is illustrated in Fig. 4.1(a), where the distribution of the reconstructed faulty samples is shifted from the original faulty data. Thus, exploiting the reconstruction error is a simple and effective way of detecting any shift in the probability distribution of the monitoring data space caused by an anomaly.

The simplicity of reconstruction-error-based detection is thanks to the fact that the model captures the characteristics of a healthy state. Furthermore, it does not require analyzing complex failure data, or any expert-dependent labeling. This concept involving the calculation of the difference of the residual outputs between monitoring and normal states has been used as a system-wide HI in several papers (Pandiyan, Prost, Vorlaufer, Varga & Wasmer, 2021; Yang & Zhang, 2021; Chen, Liu, Xia, Wang & Lai, 2020; Hong, Bang & Kim, 2021; Ásgeir Daniel Hallgrímsson, Niemann & Lind, 2020, 2021; Cheng, Cai, Liao, Wu & Dubey, 2021; Liang, Duan, Bennett & Mba, 2020; Coraça, Ferreira & Nóbrega, 2023; Booyse, Wilke & Heyns, 2020).

#### 4.2.3 Limitations of the latent manifold for fault detection

In the case where only healthy data are inferred on the latent manifold, the inference transition function is less sensitive to anomalous data than is the generative transition function. Indeed, in

most papers in which the latent manifold is used for fault detection, the main HI is a combination of the data HI and the latent HI (Zemouri, Ibrahim & Tahan, 2023; Liu *et al.*, 2021a; Wang, Forbes, Gopaluni, Chen & Song, 2019a; Cheng, He & Zhao, 2019; Lee, Kwak, Tsui & Kim, 2019; Zheng *et al.*, 2023; Tang, Peng, Dong, Zhang & Zhao, 2020).

The main advantage of the inference process over the generative process is that the latent manifold improves the interpretability of the fault detection model. Indeed, the disentangled latent manifold provides analysts and O&M practitioners with a visual tool. The representation of the LVs within time gives a graphical description for the evolution of the system's physical condition. Improving the sensitivity of the latent manifold for fault detection is thus of foremost importance.

Several latent manifold conceptual indicators could be incorporated to improve the detection of any deviation from the learned healthy state in the latent space (Balshaw, Heyns, Wilke & Schmidt, 2023). These latent conceptual indicators are the likelihood-based indicator, the discriminative indicator, the statistical distance-based indicator, the prototypical approaches, and the multivariate signal processing approaches (Balshaw *et al.*, 2023). Balshaw, Heyns, Wilke & Schmidt (2022) conducted a comparative study evaluating several latent manifold conceptual indicators. The authors concluded that data space HIs outperform latent space HIs. It was also highlighted that the temporal structure of the data must be considered to increase the sensitivity of the latent space to the anomalous data. This temporal preservation of the latent manifold involves the use of a sliding time window  $W_t$  in the latent space from which the latent HI is developed, i.e., the latent HI can be written as  $LHI = F(\mathbf{z}_t)$ , where  $F(\cdot)$  is a latent manifold conceptual indicator and  $t \in [t_1, t_2]$ . The temporal preservation of the latent variables demonstrated better performance in detecting anomalies in vibration signals than in the conventional static case (Ibrahim *et al.*, 2023).

Furthermore, to improve the interpretability of the latent manifold, it would be more appropriate to include some failure data during the learning process. This can be done in a semi-supervised

way, with the expert analyzing some failure data before the learning process, or in an unsupervised way, where the expert analyzes the clusters obtained by the inference function (after the training).

One of the restrictions on the LVM is that the inference process is unique to a given asset and very sensitive to the obtained hyperparameters set during the training. Moreover, the posterior latent distribution of the healthy data is unknown. Because of these limitations of the LVM, a universal latent HI suitable for several assets cannot be defined. As shown in Fig. 4.1(b), all the samples of the training set (faulty and healthy) lie within the same manifold, while the healthy distribution is not known a priori.

In addition, the posterior latent distribution could be unsuitable for some of the conceptual indicators of the manifold, as depicted in Fig. 4.2. Indeed, in this figure, it can be noted that point  $P_1$  is equidistant to the centroids of the clusters  $\Omega_A$  and  $\Omega_B$ , but  $P_1 \in \Omega_A$ . Also, the Euclidean distance is the same between the cluster  $\Omega_C$  centroid and points  $P_1$  and  $P_2$ , even if  $P_2 \in \Omega_C$  and  $P_1 \notin \Omega_C$ . Both cases suggest that the relations between points and clusters in the latent space cannot be described using solely the Euclidean distance.

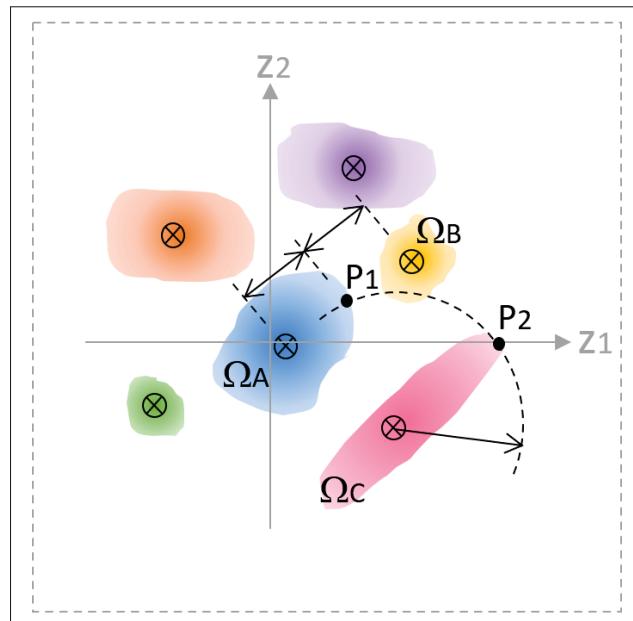


Figure 4.2 Illustration of a 2-D LVM-latent space distribution for a multiple condition database

#### 4.2.4 Toward an enhanced latent manifold for fault detection

We introduce here an approach that leads to a standard and known posterior healthy distribution. As described in this section and illustrated further in this paper, our proposition allows us to overcome the limitations of classical latent space representations. Ultimately, the enhanced representation space is used in the definition of HI for the detection of abnormal conditions in complex systems.

To achieve a standardized representation space, a second-step inference transition function is introduced to map the latent manifold into a new manifold, as shown in Fig. 4.1(c). The inference function is the NT (Nataf, 1962; Li, Lü & Yuan, 2008), which is presented in detail in section 4.3.

The NT takes the healthy dataset from the latent space as a reference. Let  $\mathbb{Z}_{\text{healthy}}$  be the set of healthy data points in the latent manifold. The NT maps  $\mathbb{Z}_{\text{healthy}}$  into  $\mathbb{S}_{\text{healthy}}$  such that  $\mathbb{S}_{\text{healthy}} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$ . Given a data point  $\mathbf{s}^{(i)} \in \mathbb{S}_{\text{healthy}}$ , let  $d^{(i)} = \|\mathbf{s}^{(i)}\|_2$ , where  $\|\cdot\|_2$  is the Euclidean norm, and  $D = d^{(i)}$  is the corresponding random variable. Since  $\mathbb{S}_{\text{healthy}} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$ , the random variable  $D$  follows the  $\chi$  distribution with  $N$  degrees of freedom  $\chi_N$ . Specifically, the norm of points in healthy condition in the standard Nataf space is characterized by the density function  $f_{\chi_N}(d)$  and the cdf  $F_{\chi_N}(d)$  (Krishnaiah, Haggis,Jr & Steinberg, 1963). This property allows defining HI based on the comparison between the Nataf space projection of datasets and the healthy reference condition. The latter is the same for any asset. Therefore, the NT provides a standard reference for defining a universal HI. Moreover, standard and universal thresholds can be set to quantify the degradation over time. Section 4.4 presents a condition monitoring approach based on the standard Nataf space manifold.

### 4.3 Nataf Isoprobabilistic Transform

The NT was introduced by Nataf (1962) and is an important tool in reliability analysis (Der Kiureghian & Liu, 1986). Its goal is to transform an intricate probabilistic description into a more tractable one (Lebrun & Dutfoy, 2009). This section briefly describes the NT.

Let the random vector  $\mathbf{Z} = [Z_1, \dots, Z_N]^T$  and the correlation matrix  $\mathbf{R}_Z$  be the probabilistic model describing the complex system, where each component corresponds to one specific feature or measure. The NT maps  $\mathbf{Z}$  into the target description  $\mathbf{S} = [S_1, \dots, S_N]^T \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$ , where  $\mathbf{0}$  is the null vector (length  $N$ ), and  $\mathbf{I}$  is the identity matrix (size  $N \times N$ ). Fig. 4.3 depicts the NT for a two-dimensional latent space. In this figure, the cdf  $F(d)$  of the distance metric  $d$  is plotted (continuous orange line) against the  $\chi_2$  cdf (dashed blue line) for each representation space.

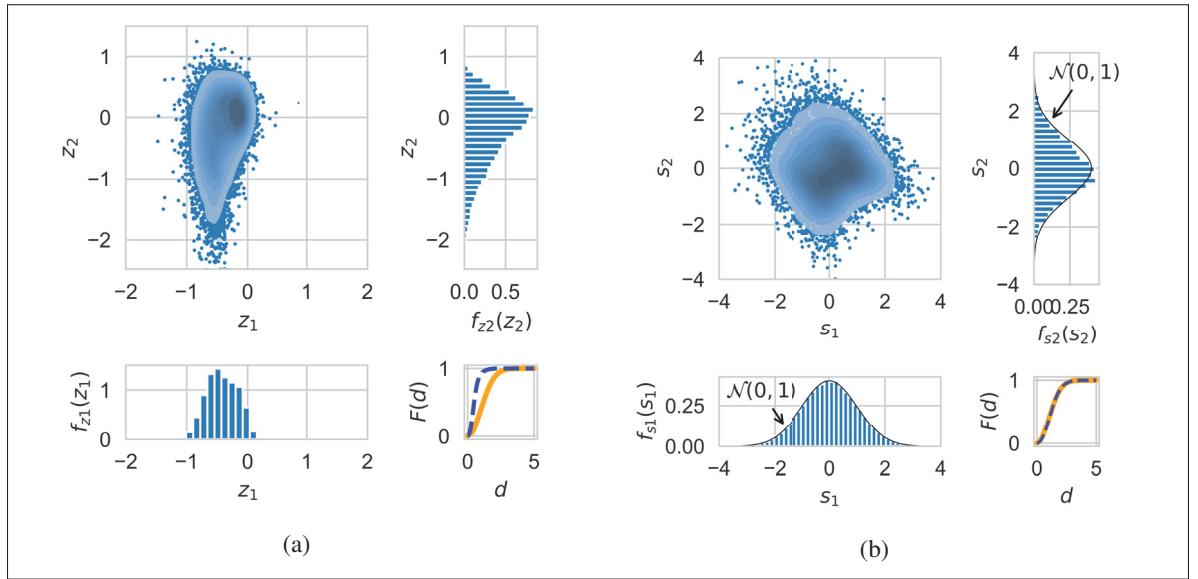


Figure 4.3 The NT maps (a) the latent space distribution  $\mathbf{Z} = [Z_1, Z_2]^T$  into (b) the standard Nataf space  $\mathbf{S} = [S_1, S_2]^T \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$

The NT can be written as the composition of two transformations  $\mathcal{T} = \mathcal{T}_1 \circ \mathcal{T}_2$  (Lebrun & Dutfoy, 2009). First,  $\mathcal{T}_1 : \mathbf{Z} \mapsto \mathbf{U}$  is given by Eq. (4.1), where  $\Phi$  is the cdf of the normal distribution  $\mathcal{N}(0, 1)$ , and  $F_i : \mathbb{R} \rightarrow [0, 1]$  is the marginal cdf of  $Z_i$ . The function  $F_i$  is known a priori, or otherwise, can be estimated from samples with a kernel density estimator.

$$U_i = \Phi^{-1}(F_i(Z_i)) \quad i \in \{1, \dots, N\} \quad (4.1)$$

The random vector  $\mathbf{U}$  resulting from Eq. (4.1) is assumed to be a Gaussian vector with marginal distributions  $\mathcal{N}(0, 1)$ . The components  $U_1, \dots, U_N$  are characterized by the correlation matrix

$\mathbf{R}_U \in \mathbb{R}^{N \times N}$ , which is referred to as the fictive correlation matrix. The transformation  $\mathcal{T}_2$  maps  $\mathbf{U}$  into the random vector  $\mathbf{S}$  with uncorrelated components. For this, let the matrix  $\mathbf{L} \in \mathbb{R}^{N \times N}$  be the Cholesky decomposition of the inverse of  $\mathbf{R}_U$ , as in Eq. (4.2).

$$\mathbf{LL}^T = \mathbf{R}_U^{-1} \quad (4.2)$$

The transformation  $\mathcal{T}_2 : \mathbf{U} \mapsto \mathbf{S}$  is given by Eq. (4.3), and the space of the variable  $\mathbf{S}$  is referred to as the standard Nataf space :

$$\mathbf{S} = \mathbf{LU} \quad (4.3)$$

Estimating the fictive correlation matrix components  $r_{Uij} = \{\mathbf{R}_U\}_{ij}, i, j \in \{1, \dots, N\}$ , is a key step in the definition of  $\mathcal{T}_2$ . Section 4.3.1 presents the numerical method allowing to estimate  $r_{Uij}$  from the correlation coefficients  $r_{Zij} = \{\mathbf{R}_Z\}_{ij}, i, j \in \{1, \dots, N\}$ . Also, the computation of  $r_{Uij}$  does not converge when the components of the healthy cluster distribution are highly correlated, i.e.,  $r_{Zij} \approx 1$ . In such a case, the NT fails to map the initial distribution into a multivariate distribution with non-correlated components (Li *et al.*, 2008).

#### 4.3.1 Estimation of the Nataf correlation coefficients

This section presents the numerical method allowing to estimate the fictive correlation coefficients  $r_{Uij} = \{\mathbf{R}_U\}_{ij}$  of the NT.

Let  $r_{Zij} = \{\mathbf{R}_Z\}_{ij}$  be the correlation coefficient between the physical space variables  $Z_i$  and  $Z_j, i, j \in \{1, \dots, N\}$ . The relation between the correlation coefficients  $r_{Uij}$  and  $r_{Zij}$  for given  $i, j \in \{1, \dots, N\}$  is given by Eq. (4.6). In this integral equation,  $\mu_{Zi}$  and  $\sigma_{Zi}$  are the average and standard deviation of  $Z_i$ , respectively, and  $\varphi_2$  is the probability density for a bi-variate Gaussian distribution with correlation  $r_{Uij}$ , as given by Eq. (4.7) (Li *et al.*, 2008).

$$\begin{aligned}
r_{Zij} &= \mathbb{E} \left[ \left( \frac{Z_i - \mu_{Zi}}{\sigma_{Zi}} \right) \left( \frac{Z_j - \mu_{Zj}}{\sigma_{Zj}} \right) \right] = \mathbb{E} \left[ \left( \frac{F_i^{-1}(\Phi(U_i)) - \mu_{Zi}}{\sigma_{Zi}} \right) \left( \frac{F_j^{-1}(\Phi(U_j)) - \mu_{Zj}}{\sigma_{Zj}} \right) \right] \\
&= \frac{1}{\sigma_{Zi}\sigma_{Zj}} \iint_{\mathbb{R}^2} \left\{ (F_i^{-1}(\Phi(u_i)) - \mu_{Zi})(F_j^{-1}(\Phi(u_j)) - \mu_{Zj}) \cdot \varphi_2(u_i, u_j, r_{Uij}) \right\} du_i du_j
\end{aligned} \tag{4.6}$$

$$\varphi_2(u_i, u_j, r_{Uij}) = \frac{1}{2\pi\sqrt{1-r_{Uij}^2}} \exp \left( -\frac{u_i^2 - 2r_{Uij}u_iu_j + u_j^2}{2(1-r_{Uij}^2)} \right) \tag{4.7}$$

$$r_{Zij} \approx \sum_{\ell=1}^m \sum_{k=1}^m p_\ell p_k \left( \frac{z_{i,\ell} - \mu_{Zi}}{\sigma_{Zi}} \right) \left( \frac{z_{j,k} - \mu_{Zj}}{\sigma_{Zj}} \right) \tag{4.8}$$

The m-points Gauss–Hermite quadrature is employed for the approximation of Eq. (4.6), which is given by Eq. (4.8). The integral equation can then be recursively solved by using Algorithm 4.1. It takes  $r_{Zij}$  as input to estimate  $r_{Uij}$ . The settings are the error tolerance  $\epsilon_{tol} > 0$ , the maximum number of iterations  $N_{max} \gg 1$ , and the Gauss–Hermite quadrature order  $m$  with the respective roots and weights. For example, Table 4.1 gives the Gauss–Legendre quadrature roots and weights for the order  $m = 7$  (Li *et al.*, 2008).

The joint probability density function (pdf)  $\varphi_2(u_i, u_j, r_{Uij})$  is not defined when  $|r_{Uij}| = 1$ , i.e., when  $Z_i$  and  $Z_j$  are correlated variables (See Eq. (4.7)). More generally, the integral equation given by Eq. (4.6) is not guaranteed to have a solution when the correlation coefficient is close to one (Lebrun & Dutfoy, 2009). In practice, Algorithm 4.1 does not converge in such cases, which means that there is no uncorrelated set of variables that is equivalent to the original set in terms of probability description.

Setting the representation space dimension as  $N = 2$  allows to easily plot these spaces, therefore defining a built-in visualization tool. Moreover, the 2-D NT requires the estimation of only one correlation coefficient  $r_{U12}$ . In this paper, the NT is defined with respect to the healthy cluster projected into a 2-D LVM space. Let  $Z_1^{HY}$  and  $Z_2^{HY}$  be the two coordinates associated with the latent space distribution of the healthy cluster. From  $Z_1^{HY}$  and  $Z_2^{HY}$ , one can estimate the

Algorithme 4.1 Nataf Fictive Correlation Coefficient Evaluation

**1 Algorithme :** Nataf Fictive Correlation Coefficient Evaluation

**Input :**  $r_{Zij}$

**Output :**  $r_{Uij}$

**Settings :**  $\epsilon_{tol}$ ,  $N_{max}$ , Gauss–Hermite quadrature order  $m$  with respective roots  $\{s_1, \dots, s_m\}$  and weights  $\{p_1, \dots, p_m\}$

```

2  $t \leftarrow 0;$ 
3  $r_{Uij}^{(t)} \leftarrow r_{Zij};$ 
4  $\epsilon \leftarrow \infty;$ 
5 while  $|\epsilon| > \epsilon_{tol}$  and  $t < N_{max}$  do
6    $t \leftarrow t + 1;$ 
7    $R^{(t)} \leftarrow \begin{pmatrix} 1 & r_{Uij}^{(t-1)} \\ r_{Uij}^{(t-1)} & 1 \end{pmatrix};$ 
8    $\hat{L}^{(t)} \leftarrow$  Cholesky decomposition of  $R^{(t)}$ ;
9    $\begin{pmatrix} u_{i,\ell}^{(t)} \\ u_{j,k}^{(t)} \end{pmatrix} \leftarrow \hat{L}^{(t)} \begin{pmatrix} s_{i,\ell}^{(t)} \\ s_{j,k}^{(t)} \end{pmatrix}, \forall \ell, k \in \{1, \dots, m\};$ 
10   $\begin{pmatrix} z_{i,\ell}^{(t)} \\ z_{j,k}^{(t)} \end{pmatrix} \leftarrow \hat{L}^{(t)} \begin{pmatrix} F_i^{-1}[\Phi(u_{i,\ell}^{(t)})] \\ F_j^{-1}[\Phi(u_{j,k}^{(t)})] \end{pmatrix}, \forall \ell, k \in \{1, \dots, m\};$ 
11   $r_{Zij}^{(t)} \leftarrow \sum_{\ell=1}^m \sum_{k=1}^m p_\ell p_k \left( \frac{z_{i,\ell} - \mu_{Zi}}{\sigma_{Zi}} \right) \left( \frac{z_{j,k} - \mu_{Zj}}{\sigma_{Zj}} \right);$ 
12   $\epsilon \leftarrow r_{Zij} - r_{Zij}^{(t)};$ 
13   $r_{Uij}^{(t)} \leftarrow r_{Uij}^{(t-1)} + \epsilon;$ 
14 end while
15  $r_{Uij} \leftarrow r_{Uij}^{(t)};$ 
16 if  $t \geq N_{max}$  then
17    $r_{Uij}^{(t)} \leftarrow NaN;$ 
18   print “Did not converge.”;
19 end if

```

empirical cdfs  $F_1(z_1)$  and  $F_2(z_2)$ , and the Pearson correlation coefficient  $r_{Z12}^{HY}$ . Then,  $r_{U12}^{HY}$  is estimated using Algorithm 4.1. For notation simplicity, let  $\rho = r_{U12}^{HY}$ . Then, provided that  $\rho \neq \pm 1$ , the correlation matrix  $[1, \rho; \rho, 1]$  is invertible. Then, the NT is completely defined by Eq. (4.9) and Eq. (4.10), where  $\Phi$  is the cdf of the normal distribution  $\mathcal{N}(0, 1)$ .

Tableau 4.1 7-Point Gauss–Hermite quadrature

<b>Roots (<math>x_i</math>)</b>	<b>Weights (<math>w_i</math>)</b>
$\pm 3.75043971768$	0.000548268858737
$\pm 2.36675941078$	0.0307571239681
$\pm 1.1544053948$	0.240123178599
0.0	0.457142857143

$$\begin{pmatrix} u_1 \\ u_2 \end{pmatrix} = \begin{pmatrix} \Phi^{-1}[F_1(z_1)] \\ \Phi^{-1}[F_2(z_2)] \end{pmatrix} \quad (4.9)$$

$$\begin{pmatrix} s_1 \\ s_2 \end{pmatrix} = \begin{pmatrix} u_1 \\ \rho u_1 + \sqrt{1 - \rho^2} u_2 \end{pmatrix} \quad (4.10)$$

## 4.4 Proposed Condition Monitoring Approach

This section introduces a new CM approach aimed at the early detection of abnormal conditions in complex systems. The proposed approach is based on HIs defined from the standard Nataf space representation. The implementation of the approach comprises two phases : online and offline. The offline phase defines the building blocks that later constitute the online phase's pipeline. The offline phase comprises three steps : (a) definition and labeling of the database, (b) training of the VAE model, and (c) definition of the NT. The online phase estimates the condition status from the normalized dataset  $\mathbf{x}_\tau = \{\mathbf{x}(t), t \in \tau\}$ . Fig. 4.4 depicts these two phases of the implementation with their respective steps, which are described in detail in the following sections.

### 4.4.1 Database definition and latent space representation

We assume that the complex system is described by multiple measures. Although LVMs such as the VAE are capable of processing many features and suit feature learning (Kingma & Welling,

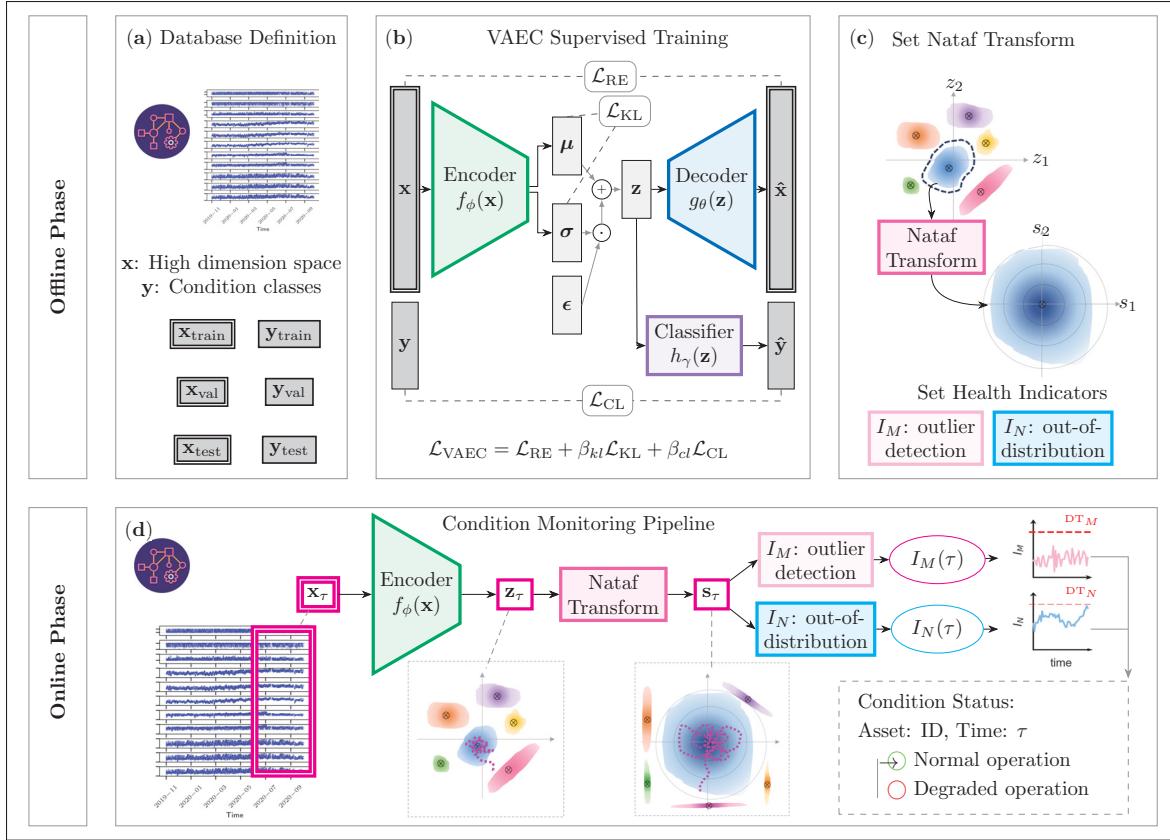


Figure 4.4 Framework of the proposed condition monitoring approach for a system operating under multiple conditions

2014), a feature engineering analysis is recommended to select the pertinent measures. In particular, recent literature suggests that the latent space representation is enhanced by restricting the features to non-correlated measures with high informative power (Cheng & Chen, 2022). The offline phase of the proposed approach requires labeled data in two steps : first, training the VAE model (or similar) and then defining the NT. In the training process, the need for labels depends on the complexity of the system and on the available measures describing the state of the complex system. The final latent space representation must be such that the healthy cluster is as disentangled as possible from other condition clusters. For simpler systems or high informative features, the unsupervised VAE can eventually project the different conditions into disentangled clusters. However, the VAE is usually not sufficient to disentangle categorical clusters for complex real-life systems or relatively noisy measures. To ensure the disentanglement

of clusters in the latent representation space for these cases, supervised (or semi-supervised) implementations of the VAE are recommended.

The latent space representation is strongly influenced by the model hyperparameters, and therefore, these hyperparameters can be used to adjust the distribution of clusters in that representation. Choosing suitable hyperparameters leads to disentangled clusters in the latent space. Additionally, to ensure the convergence of the NT, the healthy cluster coordinates must be weakly correlated, i.e., have small correlation coefficients  $r_{Uij}$ ,  $i, j \in \{1, \dots, N\}$ . This requirement is further discussed in section 4.3.1.

In summary, to apply our approach, the database and its latent space representation must verify three conditions to ensure that the NT is successfully defined.

- The training database must be labeled, or at least, the healthy data must be identified from the degraded conditions.
- In the latent representation space, the cluster of healthy points must be disjoint with respect to any other cluster.
- In the latent representation space, the healthy cluster latent variable coordinates must be weakly correlated.

Overall, these requirements are easily met when the appropriate model is chosen for the latent space projection. As discussed later in this text, using the NT broadens the range of suitable hyperparameters. In other words, the use of the NT mapping relaxes the requirements on the model defining the latent space representation.

#### 4.4.2 Standard Nataf space representation

The NT is defined with respect to the healthy condition cluster, as depicted in Fig. 4.4 (c). It then maps any point in the latent space into the standard Nataf space. Fig. 4.5 illustrates a typical standard Nataf space for a multiple condition system, where  $\mathbf{s} = [s_1, s_2]^T$  is a point and  $d(\mathbf{s}) = \|\mathbf{s}\|_2$ . The random vector  $\mathbf{S}_{HY}$  describes the distribution of the reference healthy cluster.

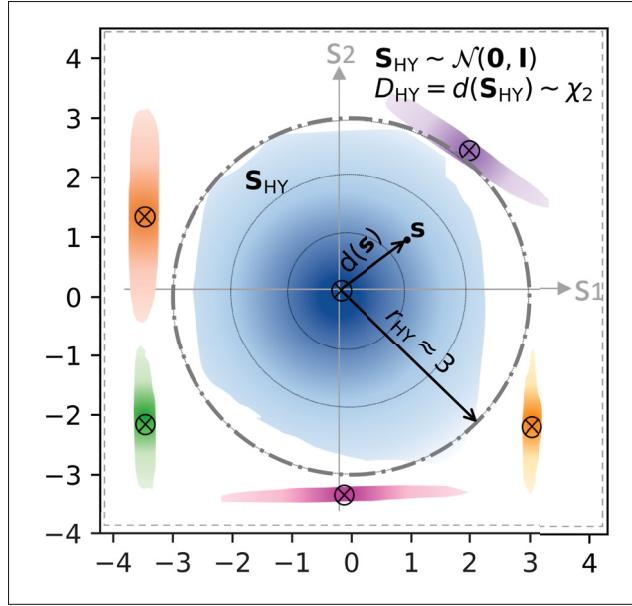


Figure 4.5 Illustration of a 2-D standard Nataf space projecting a multiple condition dataset

From the latent space representation, the definition of the NT comprises the following steps :

1. Characterize the healthy cluster in the latent space database. Specifically, estimate the empirical cdfs corresponding to the LVs  $\{Z_1, \dots, Z_N\}$ , and the correlation matrix  $\mathbf{R}_Z$  between these LVs.
2. Estimate the fictive correlation matrix  $\mathbf{R}_U$  from  $\mathbf{R}_Z$  using the algorithm presented in section 4.3.1 ;
3. Validate the NT. In the standard Nataf space, verify that the healthy cluster approximates the multivariate normal distribution and that the norm of all healthy points approximates the  $\chi_N$  distribution.

If the computation of the fictive correlation matrix does not converge, one should re-train the VAE-like model to obtain non-correlated latent space variables.

The Euclidean norm in the standard Nataf space is highly representative of the relation between data points and the reference dataset. For instance, points distributed similarly to the reference

condition in the physical space are mapped by the NT within the reference cluster in the standard Nataf space. More importantly, the projection of a healthy dataset into the standard Nataf space gives a cluster distributed as the healthy reference (see Dataset A in Fig. 4.6). For reference, the healthy cluster radius is defined as the percentile  $P_{99}$  of the  $\chi_N$  distribution. In a 2-D standard Nataf space, for example, this radius is  $r_{HY} = P_{99}[\chi_2] \approx 3$ .

Conversely, abnormal datasets projected in the standard Nataf space are inconsistent with the normal multivariate distribution of healthy conditions. Indeed, degraded datasets can manifest in the standard Nataf space in two different patterns : a sudden and rapid degradation, or continuous and slow degradation. In the first type, illustrated by Dataset B in Fig. 4.6, the complex system reaches failure within a few time steps. In such a case, the norm of successive data points goes rapidly from typical values to above the radius  $r_{HY}$ . The second degradation type is illustrated by Dataset C in Fig. 4.6. This degradation pattern manifests as a shift in the distribution of points in

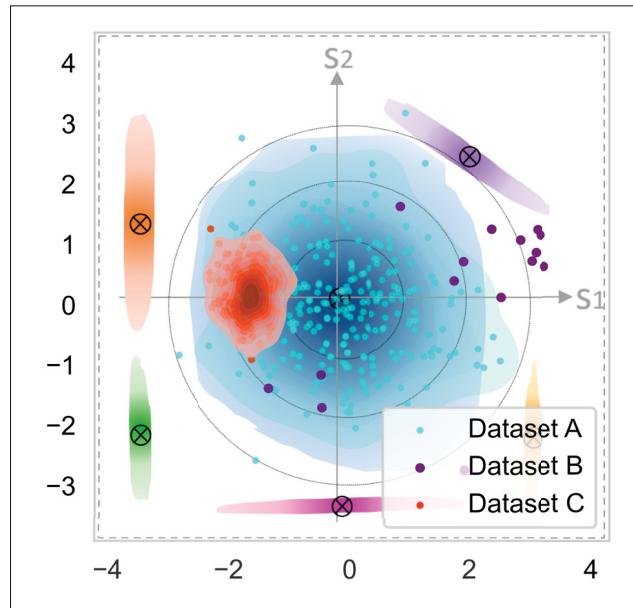


Figure 4.6 Projection of datasets in the standard Nataf space : dataset A represents a healthy dataset, whereas B and C correspond to two degradation patterns

the standard Nataf space. In this case, the norm of the projected points does not necessarily go beyond the reference radius  $r_{HY}$ .

Accordingly, we introduce below two complementary HIs using the Euclidean norm of points in the standard Nataf space :  $I_M$  and  $I_N$ . The HI  $I_M$  aims at detecting outliers more sensitive to rapid degradation with a few monitoring samples, whereas the HI  $I_N$  is an out-of-distribution detector more sensitive to the slow degradation, but that needs more samples within sliding time windows.

#### 4.4.3 Health index $I_M$ for outlier detection

The HI  $I_M$  is the Euclidean norm of the point  $\mathbf{s}(t)$  in the standard Nataf space, as given by Eq. (4.11).

$$I_M(t) = d(\mathbf{s}(t)) \quad (4.11)$$

The base alarm criterion for  $I_M$  is defined by the threshold rule  $I_M(t) > DT_M$ , where  $DT_M$  is a detection threshold to be set. Since the distribution of the norm statistics for healthy datasets is known to be the  $\chi_N$ , a general  $DT_M$  value can be set. For example, one can set  $DT_M = P_{99}[\chi_N]$ , which is valid for any kind of complex system. Also, for any system whose data is projected in a 2-D Nataf space ( $N = 2$ ),  $DT_M = P_{99}[\chi_2] = 3.0$  is a suitable value. An alternative method for defining the value of  $DT_M$  consists in using historical data from healthy systems. First, the  $I_M$  is estimated for systems known to be in healthy condition. Then,  $DT_M$  can be set as a percentile of the distribution of the estimated  $I_M$ . This work analyzes these two techniques to define  $DT_M$ .

It is recommended to associate the base detection criterion with a persistence criterion to limit the frequency of false alarms. For example, Eq. (4.12) establishes that an alarm is triggered when the base criterion is met four consecutive times. In practice, the alarm base and persistence criteria should be adapted to match the characteristics of the system of interest.

$$I_M(t_i) > DT_M \text{ for } i \in \{k, k-1, k-2\} \quad (4.12)$$

By definition,  $I_M$  allows detecting degradation modes evolving within a few time steps. Depending on the domain of the complex system under analysis, the detection anticipation might not be sufficient to allow planning and action by O&M analysts and practitioners. Nevertheless, the pertinence of  $I_M$  might be studied case by case. Conversely, the HI  $I_N$  introduced in the next section is expected to detect the onset of degradation modes earlier than competing approaches.

#### 4.4.4 Health index $I_N$ for out-of-distribution detection

Many HIs in the literature are based on out-of-distribution detection (Hemmer *et al.*, 2020; Ramakrishna, Rahiminasab, Karsai, Easwaran & Dubey, 2022; Sundar, Ramakrishna, Rahiminasab, Easwaran & Dubey, 2020; Oliveira-Filho *et al.*, 2023). To our knowledge, no previous work has exploited the out-of-distribution detection in the standard Nataf space. The HI  $I_N$  introduced in this section was precisely designed to detect shifts in the probability distribution of datasets in the standard Nataf space.

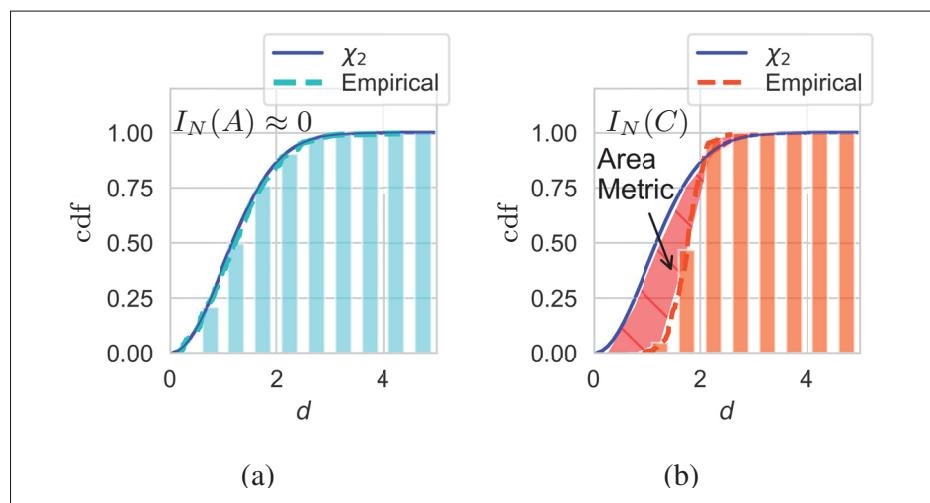


Figure 4.7 Estimation of  $I_N$  from the pdf of  $d(\mathbf{s})$  for the datasets from Fig. 4.6 (a) A and (b) C

Let  $\tau$  be a sliding period in which the complex system of interest operates. Let  $\mathbf{S}_\tau$  be a random variable describing the distribution of the projection of the dataset of interest in the standard Nataf space, within the sliding period  $\tau$ . Finally, let  $F_\tau(d)$  be the corresponding empirical cdf of  $D_\tau = d(\mathbf{S}_\tau)$ . The HI  $I_N$  is defined as the area metric between the analytical cdf  $F_{\chi_N}(d)$  and the empirical cdf  $F_\tau(d)$ , as given by Eq. (4.13) and illustrated in Fig. 4.7. In practice, the area metric can be estimated from samples of both distributions by using the Wasserstein metric (or Kantorovich–Rubinstein metric) (De Angelis & Gray, 2021; Ramdas, García Trillo & Cuturi, 2017) :

$$I_N(\tau) = \int_0^{+\infty} |F_{\chi_N}(x) - F_{D_\tau}(x)| dx \quad (4.13)$$

The definition of  $I_N$  as the area metric between two cdfs was motivated by the following considerations : (i) the reference normal multivariate distribution exhibits a spherical symmetry, and therefore, no pertinent information is lost when the analysis is based on the norm of points ; (ii) the reference distribution  $F_{\chi_N}$  is well known ; (iii) the proposed  $I_N$  does not depend on the dimension  $N$  of the latent space, and (iv) the area metric is an interpretable HI.

The base alarm criterion for  $I_N$  is given by  $I_N(\tau) > DT_N$ , where  $DT_N$  is a detection threshold to be defined. The value of  $DT_N$  can be defined by considering the distribution of  $I_N$  estimated from systems known to be in healthy condition. This distribution of  $I_N$  depends on the space dimension  $N$  as well as on the length of the period  $\tau$ .

Combining this base criterion with a persistence criterion is important to prevent false alarms. The alarm criteria retained for the HI  $I_N$  is given in Eq. (4.14). Again, these criteria might be modified according to the characteristics of the system under analysis.

$$I_N(\tau_k) < DT_N \text{ and } I_N(\tau_k) > I_N(\tau_{k-1}) > I_N(\tau_{k-2}) \quad (4.14)$$

#### 4.4.5 Online condition monitoring

The online phase is depicted in Fig. 4.4(d). The steps of the online phase are as follows :

1. VAEC encoding of the normalized SCADA dataset  $\mathbf{x}_\tau$  into the set of latent space points  $\mathbf{z}_\tau$ .
2. NT-mapping of  $\mathbf{z}_\tau$  into the standard Nataf points  $\mathbf{s}_\tau$ .
3. Estimation of the two HIs from  $\mathbf{s}_\tau$ . The HI  $I_M$  is a point-wise index. It is estimated at each time step  $t_k \in \tau$ . The HI  $I_N$  takes  $\mathbf{s}_\tau$ . It is estimated for each  $\tau$ .
4. Application of alarm criteria on the estimated HIs  $I_M$  and  $I_N$ . Combine both statuses with the “OR” logical relation, i.e., an alarm is triggered when any of the alarm criteria is met.

The online pipeline calculations are repeated periodically over periods defined by partitioning the timeline. We assume that the system data is defined over the time steps  $t_0, t_1, \dots$ . A period of operation  $\tau$  can be identified by using its starting and final time steps :  $\tau(k, k + n) = \{t_k, t_{k+1}, \dots, t_{k+n}\}$ . The corresponding normalized dataset is then  $\mathbf{x}_{\tau(k, k+n)} = \{\mathbf{x}(t_k), \dots, \mathbf{x}(t_{k+n})\}$ . The partition of the timeline into datasets  $\tau(k, k + n)$  must meet two opposing requirements. On the one hand, the datasets must be big enough to allow describing the probability distribution of clusters in the latent and the Nataf spaces. On the other hand, the promptness of the detection depends on how rapidly new data points are fed into the online pipeline. Overlapping datasets can be used to satisfy both conditions. The partition of the timeline is then defined by the length of the datasets and the lag time between the beginning of two successive datasets. A sensitivity analysis is recommended for an appropriate choice.

#### 4.4.6 Performance of the condition monitoring approach

To evaluate the performance of a detection approach, it is customary to implement it on a selection of reference study cases for which the ground-truth detection instants are known. If multiple case studies of reference are available, statistics such as accuracy, precision, F1 score, and Recall can be estimated. See (Goutte & Gaussier, 2005).

However, very often, only a few case studies are available. In such cases, one can prioritize case-specific evaluations. One primary performance metric for detection approaches is the anticipation of failure, i.e., the time between the instant when the detection approach triggers an alarm and the instant of failure (Cambron *et al.*, 2017). Since the instant of failure is rarely available, the anticipation is often estimated with a reference approach. The anticipation interval of an alarm is important for the viability of the detection approach. Indeed, the alarm anticipation must be significant enough to allow in-situ interventions, be it by shutting the system down, inspecting it, or scheduling necessary repairs.

## **4.5 Case Study I : Engine Degradation from C-MAPSS database**

This section demonstrates the proposed detection approach in the C-MAPSS FD001 dataset (Saxena, Goebel, Simon & Eklund, 2008). This dataset comprises a run-to-failure time series of commercial aircraft turbofan engines in cruise condition. C-MAPSS datasets are widely used by the PHM community, and have indeed come to constitute benchmarking datasets for multiple CM and prognosis approaches, notably the RUL estimation (Ramasso & Saxena, 2014). In this case study, we apply the proposed HIs to detect the onset of abnormal conditions defined as a function of the ground-truth RUL values. The RUL estimation itself is beyond the scope of the present paper.

### **4.5.1 The C-MAPSS FD001 dataset**

The C-MAPSS database comes from high-fidelity computational simulations of the operation of a large commercial turbofan. This case study considers the FD001 dataset, which comprises run-to-failure time series corresponding to the degradation of the turbofan in cruise condition (Arias Chao, Kulkarni, Goebel & Fink, 2021). Sensors indicate measures at the main turbofan sub-components, namely the fan, the Low-Pressure Compressor (LPC), the High-Pressure Compressor (HPC), the combustor, the High-Pressure Turbine (HPT), the Low-Pressure Turbine (LPT), and the Nozzle. These components are depicted in Fig. 4.8 (Arias Chao *et al.*, 2021).

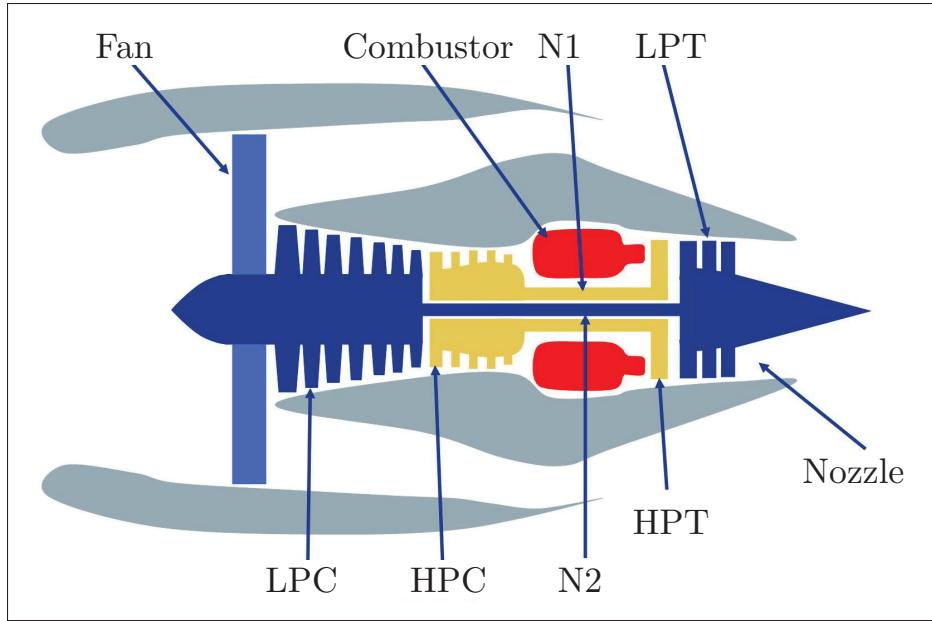


Figure 4.8 Turbofan engine from NASA's C-MAPSS  
Tirée de Frederick *et al.* (2007, p. 3)

The dataset comprises three kinds of data :

- Scenario descriptors : include major flight data such as altitude, flight Mach number, and throttle-resolver angle.
- Sensors : include 14 measurements covering temperature, total pressure, mass flux, and pressure ratio at multiple sections of the turbofan.
- cycle counting from 1<sup>st</sup> cycle at the beginning of the simulation until the failure cycle  $n_{failure}$ .

The RUL function is set as a piecewise linear degradation curve. For each run-to-failure time series, it is defined from the cycle counting data. Fig. 4.9 depicts the typical RUL function  $RUL(n) = \min\{n_{failure} - n, RUL_0\}$ , where the constant initial value is set as  $RUL_0 = 125$ . The model used to predict the RUL combines the Long Short-Term Memory (LSTM) DNN with the VAE and a Regression DNN module.

Moreover, to define the detection problem from the C-MAPSS FD001 dataset, the critical RUL value  $RUL_c$  is introduced as the threshold defining a degraded condition. That means that the relation  $RUL < RUL_c$  indicates the onset of a degrading condition. Indeed, ground-truth RUL

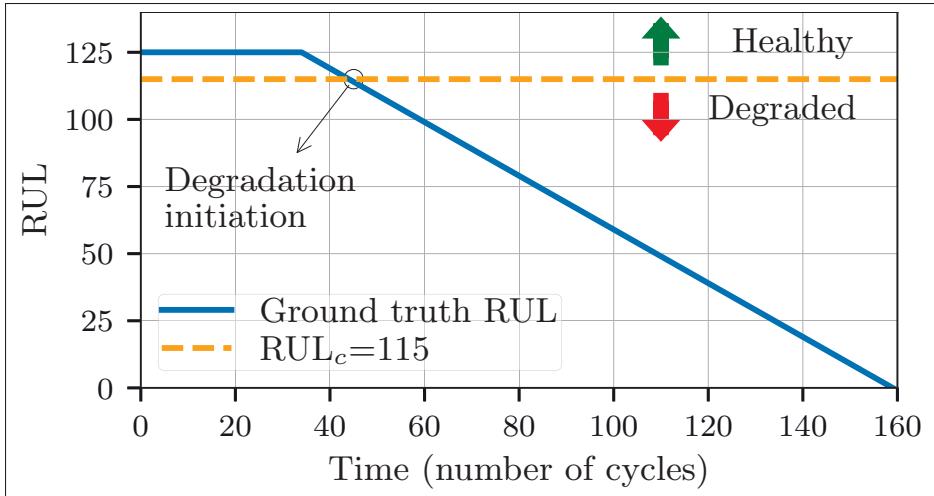


Figure 4.9 Target RUL and predicted RUL with the LSTM-VAE-Regression model

functions decrease linearly from this critical threshold. The reference degradation initiation cycle is simply the cycle at which the relation  $RUL < RUL_c$  is observed. For example, according to this criterion, the degradation starts at the 45<sup>th</sup> cycle in Fig 4.9 with  $RUL_c = 115$ .

#### 4.5.2 Latent space projection

The latent space representation of the C-MAPSS datasets has been analyzed in works such as (Costa & Sánchez, 2022; González-Muñiz, Diaz, Cuadrado & García-Pérez, 2022; Cofre-Martel, Lopez Drogueut & Modarres, 2021). The latent space projection introduced by Costa & Sánchez (2022) is suitable for demonstrating the approach we propose in the present work. Costa & Sánchez (2022) introduced a DNN model consisting of an LSTM-VAE embedded with a regression DNN. The latent space is set with dimension  $N = 2$ . The resulting latent space projection is such that the distribution of points is an indicator of the RUL value. We refer the reader to the original paper for details on the LSTM-VAE and the regression DNN, as well as architecture and training parameters (Costa & Sánchez, 2022). Nevertheless, the original model led to a cluster with mostly correlated latent variable components  $z_1$  and  $z_2$ , thus hindering the definition of the NT. To overcome this limitation, the loss function was modified by increasing the weight of the

Kullback-Liebler loss component. Fig. 4.10 depicts the resulting latent space projection of the training database.

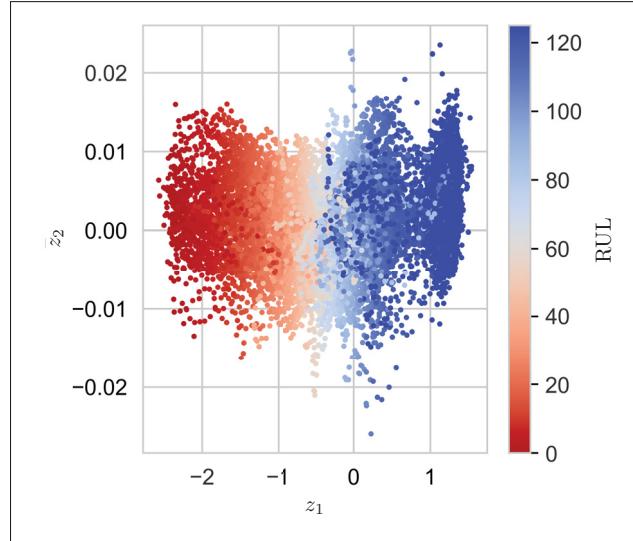


Figure 4.10 Latent space representation of the C-MAPSS FD001 dataset using the LSTM-VAE-Regression model

#### 4.5.3 Standard Nataf space and detection criteria

The reference healthy operational condition dataset comprises the training points for which the threshold relation  $RUL > RUL_c$  is met. This dataset is used as a reference for the definition of the NT. Fig. 4.11 depicts the mapping of the healthy dataset into the standard Nataf space.

The distribution of the norm of all points from the reference healthy cluster in the standard Nataf space is depicted in Fig. 4.12. It confirms a good agreement between the empirical cdf and the  $\chi_2$  cdf  $F_{\chi_2}$ .

To define the detection threshold for the two HIs,  $I_M$  and  $I_N$ , the distributions of these indices are estimated for the healthy data points, and the detection thresholds are set as the 99<sup>th</sup> percentile  $P_{99}$  of each distribution. Fig. 4.13 depicts the distributions for the two HIs obtained for the

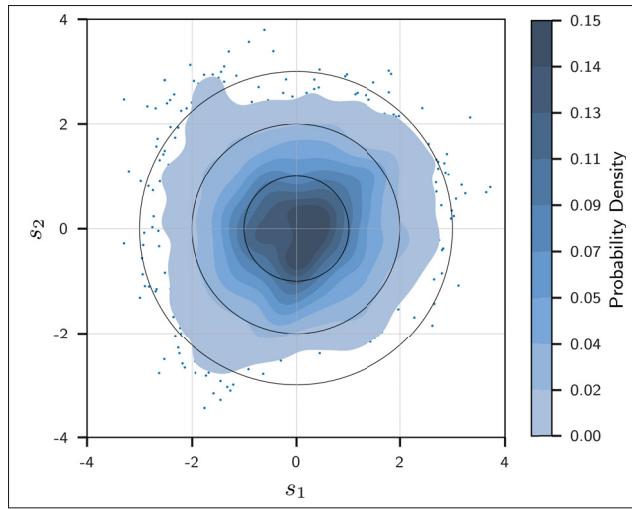


Figure 4.11 Standard Nataf space projection of the healthy condition data

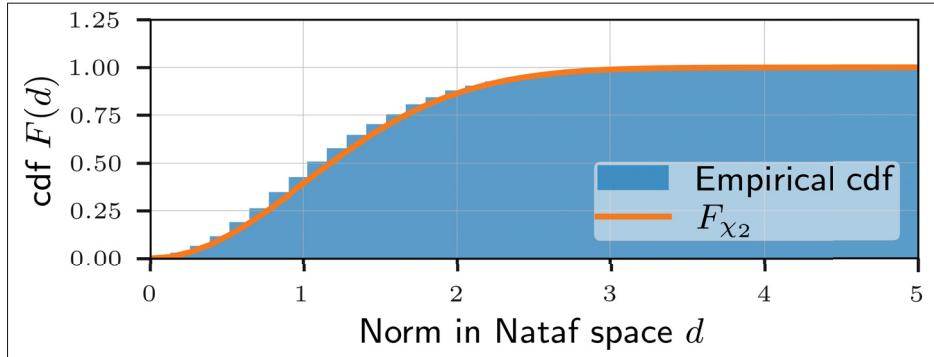


Figure 4.12 Distribution of the distance metric for the healthy condition cluster in the standard Nataf space

FD001 dataset. According to these experimental results, the alarm thresholds are respectively set as  $DT_M = 3.1$  and  $DT_N = 1.1$ .

In this case, the standardization of the healthy condition in the Nataf space eases the definition of  $DT_M$ . For instance, since the  $I_M$  is strictly equal to the norm of points, the HI  $I_M$  evaluated on a healthy dataset follows the  $\chi_N$  distribution, and thus,  $DT_M$  can be set as a percentile of the  $\chi_N$  distribution. Given  $N = 2$ , the percentile  $P_{99}$  gives  $DT_M = P_{99}[\chi_2] = 3.0$ , which is consistent with the value from the empirical distribution of  $I_M$ .

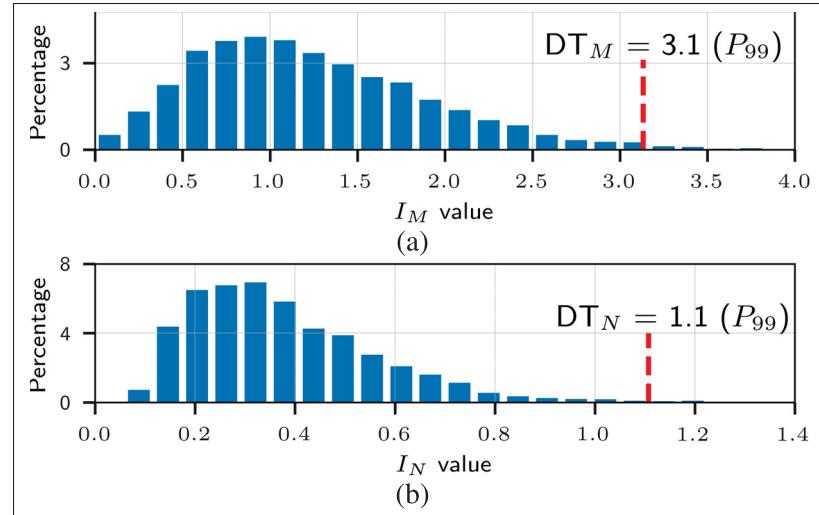


Figure 4.13 Distribution of the HIs calculated on the healthy dataset : (a)  $I_M$  and (b)  $I_N$

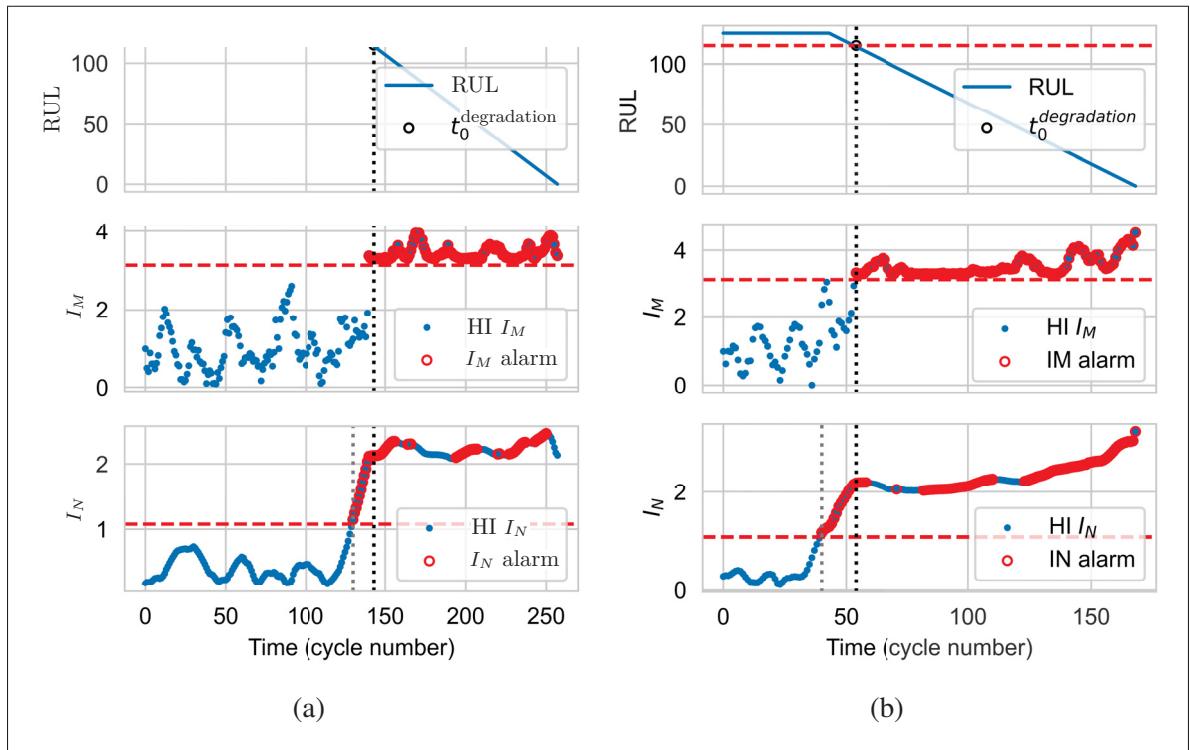


Figure 4.14 HI  $I_M$ ,  $I_N$  and alarm status for C-MAPSS FD001 datasets corresponding to (a) turbofan 2 and (b) turbofan 50

#### 4.5.4 Early detection of abnormal conditions

Once the LSTM-VAER model is trained and the NT defined, new datasets can be projected into the standard Nataf space. The estimation of the two HI  $I_M$  and  $I_N$  for engine 2 is given in Fig. 4.14(a). The reference onset of degradation for this engine occurred at the 143<sup>rd</sup> cycle. The alarm criteria led to the  $I_M$  alarm at the 140<sup>th</sup> cycle and the  $I_N$  alarm was triggered at the 130<sup>th</sup> cycle. Fig. 4.14(b) depicts the curves for  $I_M$  and  $I_N$  for engine 50. The reference onset of degradation for this engine occurred at the 56<sup>th</sup> cycle. The HI  $I_M$  detected the abnormal condition at the 53<sup>rd</sup> cycle and  $I_N$  led to an alarm at the 38<sup>th</sup> cycle.

Fig. 4.15(a) depicts the  $I_M$  detection time versus ground-truth degradation onset time for all the engines of the FD001 dataset. The HI  $I_M$  led to the same detection instants as the target values (ground-truth degradation initiation) for most cases, with no significant anticipation. This result is attributable to the characteristics of the degradation function. As specified, we assumed that  $RUL < RUL_c$  indicated the onset of degradation, and that the ground-truth RUL function is a linear function of the cycle counting.

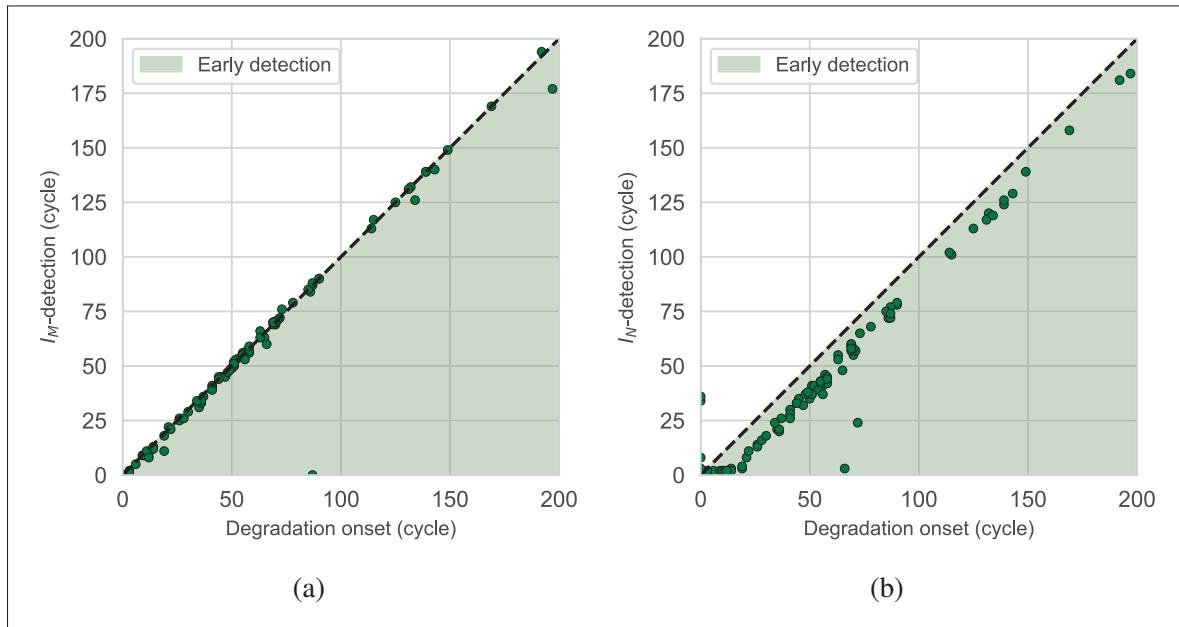


Figure 4.15 Comparison between the reference degradation initiation instant and the detection instants for HI (a)  $I_M$  and (b)  $I_N$

From Fig. 4.15(b), it can be seen that the detection by  $I_N$  anticipates the reference detection instants for almost all engines. Considering all the engines of the C-MAPSS FD001 dataset and the degradation defined above, the HI  $I_N$  led to the early detection of degraded conditions, with an anticipation of the reference degradation instant in 12 cycles on average.

## 4.6 Case Study II : Wind Turbine Condition Monitoring

This second case study demonstrates the implementation of the proposed approach on a real-life database from a North American wind farm. Modern WTs are by default equipped with the SCADA system, which generates multiple data describing the WT operation. Analyzing the high-dimensional and non-linear physical spaces resulting from the SCADA sensors is a challenging task. Latent space representations are widely used in the WT CM literature (Zhao, Liu, Hu & Yan, 2018b; Roelofs *et al.*, 2021; Rezamand *et al.*, 2020a; Oliveira-Filho *et al.*, 2023).

In particular, the authors of the present paper analyzed the case of WT CM in (Oliveira-Filho *et al.*, 2023). Our previous proposition used the Mahalanobis distance to define an HI from a latent space representation. This definition allowed a good detection performance, but required extra effort in the definition of a convenient latent space. The selection of suitable hyperparameters can be tiresome and time-consuming for complex systems such as WTs. Also, the lack of comparability between independent training instances was pointed out as a limitation. We show in the case study below that the approach proposed in the present paper outperforms the previous one and finally achieves a standardized low-dimension representation for WTs by using the NT. This second case study demonstrates the suitability of our approach to analyze real-life industrial cases.

### 4.6.1 Wind turbine SCADA database

This case study uses a proprietary database from a North American wind farm. This database contains data on over 100 onshore WTs and covers operations spanning 2 years and four months. The following are the specifications of the WTs : horizontal axis ; upwind ; three-blade rotors ;

pitch-controlled ; rated power of order  $P_n = 2 \text{ MW}$  ; cut-in wind speed  $V_{in} = 3.5m/s$  ; rated wind speed of  $V_r = 13m/s$ , and cut-off wind speed  $V_{out} = 20m/s$ .

The database comprises three kinds of information : measures from the built-in SCADA system, SCADA log files, and O&M reports. The SCADA system is composed of sensors covering measures of geometrical, kinematic, thermal, and electrical characteristics. For each measure, the available data correspond to the average value over 10-minute periods, which is particularly appropriate for performance monitoring (IEC, 2022). It is worth mentioning that vibration and acoustic measurements are not available for the WTs under analysis. The log files indicate warnings and alarms generated by the SCADA system usually based on simple threshold rules. The O&M reports are completed by the O&M practitioners based on in-field observations during inspections and repairs.

Temperature-related abnormal conditions such as the overtemperature of critical components were reported in the database and are commonly investigated in the literature using temperature measures from the SCADA system (Beretta *et al.*, 2021a; Badihi *et al.*, 2022). Table 4.2 lists the temperature-related conditions analyzed in the present paper. The color codes are defined for subsequent use in this text. The reader is referred to Rezamand *et al.* (2020a) and Cambron *et al.* (2017) for illustrations of some of these degradation modes.

Tableau 4.2 Temperature-related WT conditions with the respective color codes

ID	Description	Color code
HY	Reference healthy condition	
BEA	Main bearing overtemperature	
GBX	Gearbox oil overtemperature	
GEN	Generator overtemperature	
ICE	Ice accretion on blades	

In all, 35 SCADA measures were made available in the database. The statistical analysis of the time series corresponding to these measures revealed some variables with little or no informative power, e.g., time series with mostly non-numerical values, constant-value time series, as well

as sets of highly correlated time series. This work retained the 11 measures listed in Table 5.2. The selection includes multiple temperature measures that provide key information on the characterization of the abnormal behaviors listed in Table 4.2. The preprocessing of the SCADA measures consists of clipping and min-max normalization of data using the lower and upper bounds indicated in Table 4.3. These values follow from the statistical analysis of measures from all the WTs taken together. Data points with measures falling outside the interval  $[LB, UB]$  are removed from the database. The features are normalized into the  $[0, 1]$  interval.

Tableau 4.3 SCADA measures with the respective lower (LB) and upper (UB) bounds

Measure (Unit)	Description	LB	UB
$WS$ (m/s)	Wind speed	0	31
$n_{ROTOR}$ (rpm)	Rotor speed	0	18
$P$ (kW)	Active power	0	2000
$T_{AMB}$ ( $^{\circ}$ C)	Ambient Temp.	-25	45
$T_{NAC}$ ( $^{\circ}$ C)	Nacelle Temp.	-20	70
$T_{BEA}$ ( $^{\circ}$ C)	Main Bearing Temp.	-20	70
$T_{GBX-BEA}$ ( $^{\circ}$ C)	Gearbox Bearing Temp.	0	100
$T_{GBX-OIL}$ ( $^{\circ}$ C)	Gearbox Oil Temp.	0	100
$T_{GEN1}$ ( $^{\circ}$ C)	Generator Temp. Pos. 1	-10	140
$T_{GEN2}$ ( $^{\circ}$ C)	Generator Temp. Pos. 2	-10	140
$T_{GEN-COOL}$ ( $^{\circ}$ C)	Generator Cooling Temp.	-10	120

A labeled dataset is required for the supervised learning of the retained LVM, the VAEC model. The labeling step consists of a semi-manual selection of data points based on the indications from the SCADA log files. This step was guided by industry experts and used considerations of the physical nature of each temperature-related condition. For example, to build the dataset representing the GBX (Gearbox oil overtemperature) condition, we analyzed the evolution of the key measures  $WS$ ,  $n_{ROTOR}$ ,  $P$ ,  $T_{GBX-BEA}$ ,  $T_{GBX-OIL}$ ,  $T_{AMB}$ , and  $T_{NAC}$ . The starting point to select data points corresponding to the GBX condition is the time period of gearbox overtemperature reported in the SCADA log files. Often,  $T_{GBX-BEA}$  and or  $T_{GBX-OIL}$  become increasingly high even before the starting instant indicated in the SCADA log files. Thus, the

selected intervals were usually larger than the intervals of abnormal conditions indicated in the SCADA log files.

Given the large dispersion of the SCADA measures, many data points are required to build statistically representative datasets. Moreover, given an operating WT, only a few degradation cases, if any, are observed. Thus, it is not possible to build datasets for all conditions using data from only one unit. To overcome this limitation, we build datasets by gathering data points from multiple WTs. These WTs are supposed to have similar degradation modes since they are of the same model, are subject to the same manufacturing standards, and operate under similar wind and environmental conditions. In practice, the CM approach can be built for a subset of units from a large wind farm. Dataset augmentation techniques can be used if the number of data points for any dataset is still insufficient. Fig. 4.16 displays the datasets of interest in the normalized power curve. The ICE cluster is well separated from the other conditions and, therefore, can be detected directly from the power curve (Gao, Tao, Liu & Hu, 2021). Nevertheless, the datasets corresponding to the other critical conditions are mostly superposed, and their detection is not as straightforward as for the ICE condition. The ICE condition is included in this case study for validation of the proposed approach.

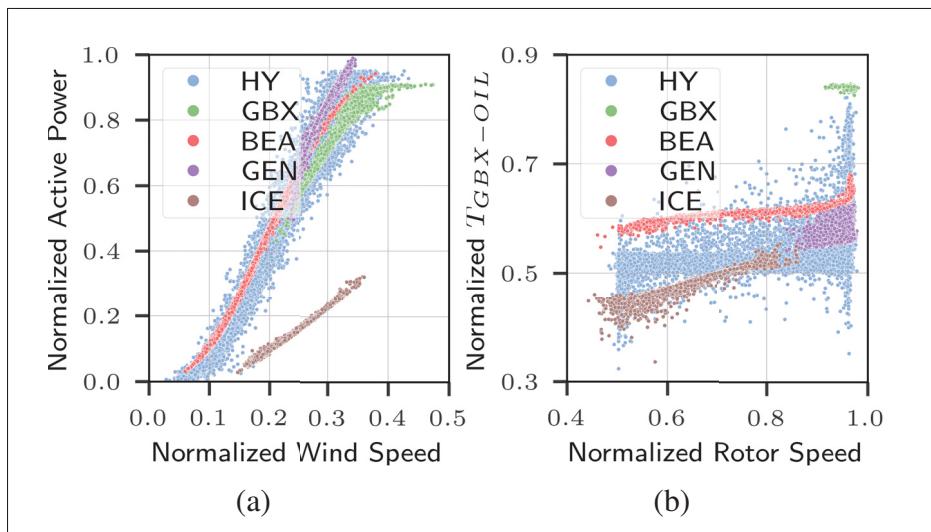


Figure 4.16 Distribution of the datasets of interest in two plots : (a) normalized power curve and (b) normalized gearbox temperature versus normalized rotor rotation speed

#### 4.6.2 VAEC model architecture and training

The proposed approach was implemented in Python (ver. 3.10). The VAEC model is built using the TensorFlow library and the Keras API (Abadi *et al.*, 2016). The supervised VAEC model was adopted since the classical (and unsupervised) VAE is not sufficient to obtain a latent space representation with disentangled clusters (Oliveira-Filho *et al.*, 2023). In accordance with the data, the input (and output) dimension is  $N_X = 11$  and the classifier DNN has its output dimension  $N_C = 5$ . The latent space dimension is set to  $N = 2$ . This choice allows to easily display the representation spaces in plots, thus defining a built-in visualization. The retained architecture is described as follows :

- Encoder : three hidden layers and one dropout layer. The number of nodes per layer is, successively, 11 (input layer), 32, 16, 8, and 2 (output layer). The input layer is set with the *ReLU* activation function, and *tanh* is used in the remaining layers of the encoder. Moreover, a 10% dropout layer is placed after the 32-node layer to prevent overfitting.
- Decoder : 2, 8, 16, and 32 nodes per layer. The decoder output layer is set with the linear activation function. The other decoder layers are set with the *tanh* activation function.
- Classification DNN : the input of the classification DNN is the latent space with dimension 2. The successive hidden layers have a decreasing number of nodes : 128, 64, 32, and 16. The *tanh* activation function is used in the input and in the hidden layers. Finally, the classification output is a five-node layer using the *Softmax* activation function.

The supervised training uses the Adam algorithm with a learning rate of 0.0001, clip value of 0.3, number of epochs 1024, and batch size set to 128 (Kingma & Ba, 2014).

#### 4.6.3 Suitable model hyperparameters and Nataf transform

One of the advantages of the proposed approach is that it relaxes the requirements for the training hyperparameters. To demonstrate this claim, this section describes the influence of the loss function hyperparameters. The VAEC loss function is given by Eq. (4.15), where  $\mathcal{L}_{RE}$  is the reconstruction error loss,  $\mathcal{L}_{KL}$  is the Kullback-Liebler loss, and  $\mathcal{L}_{CL}$  is the classifier loss. The

coefficients  $\beta_{kl} \geq 0$  and  $\beta_{cl} \geq 0$  allow to adjust the weight of each loss component in the VAEC training :

$$\mathcal{L}_{VAEC} = \mathcal{L}_{RE} + \beta_{kl} \mathcal{L}_{KL} + \beta_{cl} \mathcal{L}_{CL} \quad (4.15)$$

The loss function coefficients are hyperparameters that strongly affect the latent space distribution. For instance, Fig. 4.17 depicts three training instances of the VAEC latent space and the respective standard Nataf spaces defined taking the healthy cluster HY as the reference distribution. In each cluster, the color gradient indicates the probability density of points, with darker shades corresponding to higher density. Note in Figures 4.17(a), (c), and (e) that the latent space representations are highly variable, and this is true even when the coefficients are the same. On the contrary, the standard Nataf space gives a standardized representation of the WT healthy condition.

As a corollary, the range of suitable training hyperparameters is broader when using the NT, as compared to the latent representation based solely on the variational encoding of the data. It was indeed shown that different loss function coefficient choices lead to very different latent space outcomes, whereas in the Nataf space, the reference data invariably follows the multivariate normal distribution. The coefficients retained for the VAEC model training are  $\beta_{kl} = 0.01$  and  $\beta_{cl} = 0.1$ . Hereafter, we use the reference standard Nataf space depicted in Fig. 4.17(e-f).

#### 4.6.4 Detection thresholds

The point-wise estimation of  $d(\mathbf{s}(t))$  gives a time series with a 10-minute time step that is highly dispersed. In the WT industry, it is common to use daily averages as a means to regularize HIs (Cambron *et al.*, 2017). The definition of the  $I_M$  is adapted accordingly, as in Eq. 4.16.

$$I_M(t) = \frac{1}{n_{DAY}} \sum_{t \in DAY} d(\mathbf{s}(t)) \quad (4.16)$$

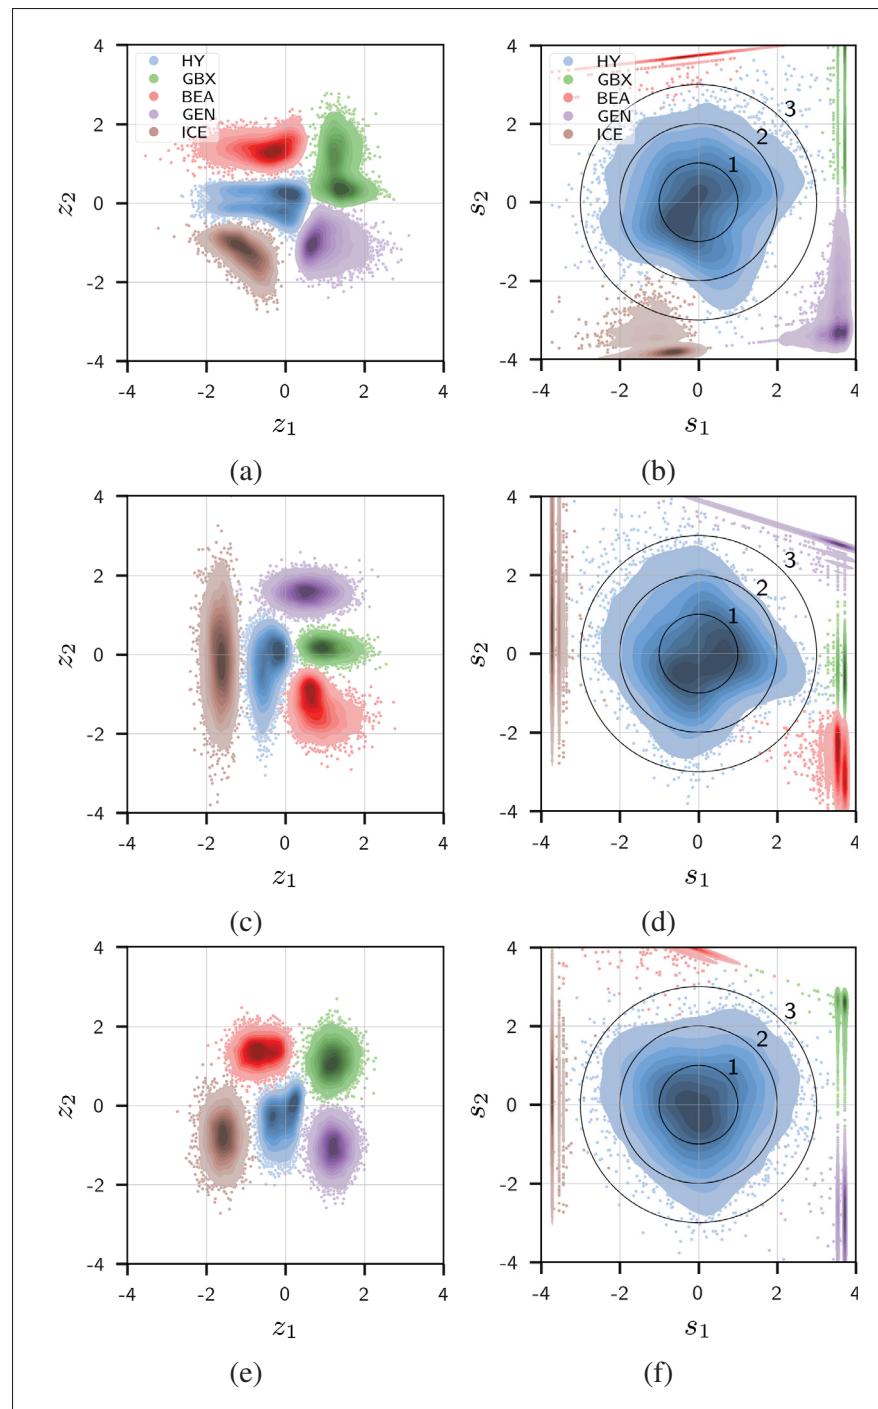


Figure 4.17 Latent space and standard Nataf space for independent training instances : (a-b)  $\beta_{kl} = 0.001, \beta_{cl} = 0.01$ , (c-d)  $\beta_{kl} = 0.01, \beta_{cl} = 0.1$ , (e-f)  $\beta_{kl} = 0.01, \beta_{cl} = 0.1$

Regarding the estimation of the out-of-distribution HI  $I_N$ , a sliding period  $\tau = 4$  days is used with a lag time  $\Delta_{lag} = 1$  day (overlap of three days between two successive periods). The detection thresholds  $DT_M$  and  $DT_N$  were set from a selection of ten datasets covering the operation of WTs known to be in healthy condition. Fig. 4.18 depicts the distribution for both HIs  $I_M$  and  $I_N$  estimated from the selection of healthy datasets. As for the C-MAPSS experiments, the detection thresholds were set as the percentile  $P_{99}$  of each distribution, which corresponds to  $DT_M = 3.0$  and  $DT_N = 1.2$ , respectively.

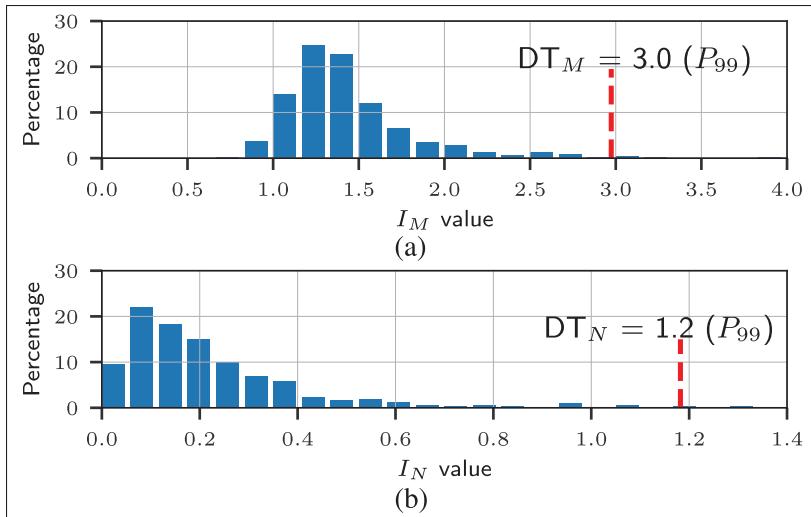


Figure 4.18 Distribution of the HIs calculated on ten selected healthy WTs : (a)  $I_M$  and (b)  $I_N$

Figures 4.19(a) and 4.19(b) depict the HIs  $I_M$  and  $I_N$  for one healthy WT, respectively. Both HI time series remain below the respective detection thresholds. Thus, as expected, no alarm is triggered for this healthy WT.

#### 4.6.5 Condition monitoring of a wind turbine impacted by multiple abnormal conditions

This case study covers the operation of one WT within the period [ $t_0=2019/10/1$ ,  $t_f=2020/8/3$ ]. The specific WT was selected from the wind farm under analysis because it had been reported to be suffering from multiple critical abnormal conditions ; in particular, blade ice accretion (ICE)

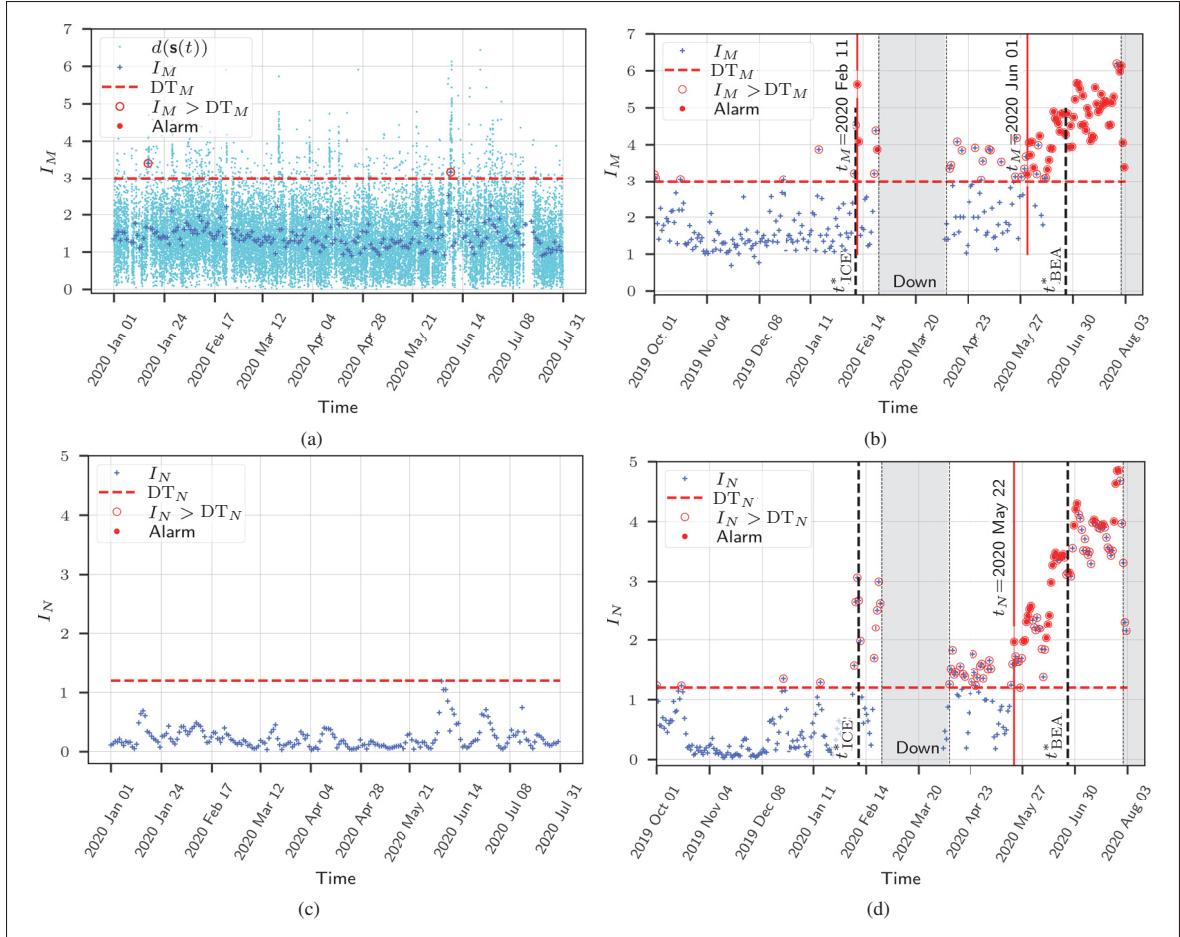


Figure 4.19 HI estimation for a healthy WT — (a)  $I_M$ , (b)  $I_N$  — and for a WT with reported main bearing overtemperature — (c)  $I_M$ , (d)  $I_N$

and main bearing overtemperature (BEA). Therefore, this WT allows to demonstrate the capacity of the proposed approach in detecting multiple types of abnormal conditions. The timeline of events was reconstructed with industry experts based on information from the SCADA log files and O&M reports. The following are the main events in the timeline :

- $t_0=2019/10/1$  : Beginning of the period of analysis.
- $t^*_{ICE}=2020/02/11$  SCADA alarm : ICE condition.
- $t_{Down1}=2020/2/24$  : Shutdown labeled as “Grid voltage fault”, and then as “Communication Loss”. Three days later, an unsuccessful start-up attempt is labeled by the SCADA system

with multiple failure modes, including the BEA condition. The unit is then kept down with “Repair” status for more than 40 days.

- $t_{StartUp}$ =2020/4/09 WT start-up.
- $t_{BEA}^*$ =2020/06/22 SCADA alarm : BEA condition.
- $t_{Down2}$ =2020/8/3 Shutdown due to BEA-related failure.
- $t_f$ =2020/8/3 End of the period of analysis.

Fig. 4.19(c) depicts the  $I_M$  time series estimated from the SCADA data using Eq. (4.16). The alarm criteria (given by Eq. (4.12) with  $DT_M = 3.0$ ) lead to a first alarm at  $t=2020/02/11$ . This alarm superposes the occurrence of ice accretion on blades that were indicated by the SCADA system. An  $I_M$  alarm is then triggered days later, at  $t=2020-02-24$ , suggesting the WT was in abnormal condition just before it was shut down for repair. The SCADA system log files report multiple possible causes for the degradation. This unit remained shut down for 45 days with “Repair” status. The actions undertaken during this period were not disclosed. The WT starts operating again at  $t_{StartUp}=2020/4/09$ . After this date, the  $I_M$  values go above the threshold  $DT_M$  erratically. It is only after  $t=2020/06/01$  that  $I_M$  becomes persistent and, thus, triggers an alarm. The  $I_M$  alarm at  $t=2020/06/01$  is 28 days before the SCADA alarm at  $t_{BEA}^*$ .

The estimation of the HI  $I_N$  over the period of interest gives the  $I_N(\tau_k)$  time series depicted in Fig. 4.19(d). As previously mentioned, each  $\tau_k$  covers four consecutive days of operation, and the lag time between two successive datasets is of one day ( $\tau = 4$  days,  $\Delta_{lag} = 1$  day). The alarm criteria (given by Eq. (4.14) with  $DT_N = 1.2$ ) led to an alarm at  $t=2020/5/22$ , which is 31 days before  $t_{BEA}^*$  and more than 2 months before  $t_{Down2}$ .

Regarding the ICE episode in February 2020, although the base criterion  $I_N > DT_N$  was met multiple times in the freezing days around  $t_{ICE}^*$ , the persistence criterion filtered out any alarm during this month. Eventually, one could adjust the alarm criteria or use specific control charts to enable alarms for rapidly evolving degradation modes. Nevertheless, in this work, the  $I_N$  alarm criteria was set to prioritize the detection of degradation evolving over the long term, i.e., within multiple days, in opposition to the HI  $I_M$  alarm, which focuses on degradation modes

evolving over the short term. The asset condition status results from the combination of the two HIs with the OR logical relation. Fig. 4.20 indicates the resulting alarm time series raised by the proposed approach for the WT under analysis. In this figure, gray fill indicates WT shut down. The proposed approach detected abnormal conditions starting at  $t=2020/02/11$  (coincides with  $t_{ICE}^*$ ),  $t=2020/02/24$  (which equals  $t_{Down1}$ ), and  $t=2020/05/22$  (which is 31 days before  $t_{BEA}^*$ ).

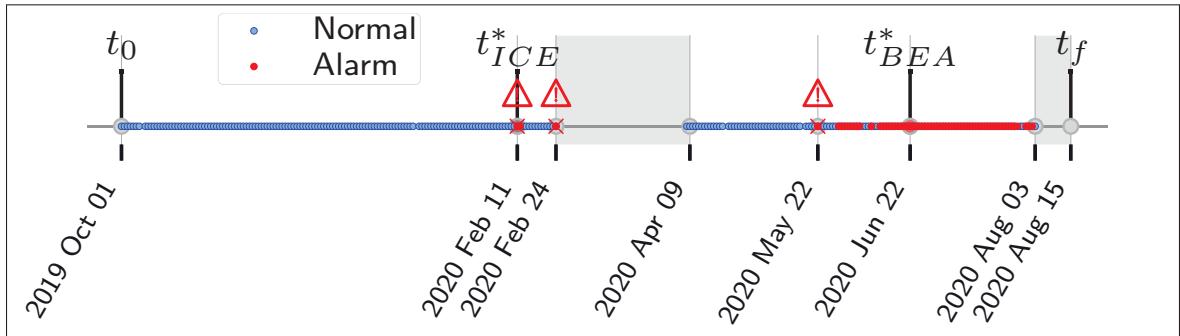


Figure 4.20 Timeline indicating dates of events and alarms in the case study

To illustrate the rationale of the HI  $I_N$  in a real-life case, the estimation of this HI is visually represented in Fig. 4.21 (See page 122). The steps for the estimation of  $I_N$  are depicted for the periods highlighted in Fig. 4.21(a), where the periods  $\tau_k$ ,  $k \in \{A, B, C, D\}$ , are :

- $\tau_A = \tau(2019/10/31, 2019/11/04)$ .
- $\tau_B = \tau(2020/01/10, 2020/01/14)$ .
- $\tau_C = \tau(2020/04/18, 2020/04/22)$ .
- $\tau_D = \tau(2020/06/07, 2020/06/11)$ .

Each row of Fig. 4.21 shows the evolution of the abnormal condition over the four selected datasets. In the latent space representation in Fig. 4.21(b), it is remarkable that the dataset distribution evolves from the healthy cluster toward the main bearing overtemperature cluster (BEA). This progression is also visually evidenced in the standard Nataf space in Fig. 4.21(c), and even more so in the area metric between the empirical cdf and the  $\chi_2$  cdf in Fig. 4.21(d).

Finally, Fig. 4.22(a) and Fig. (b) depict the time evolution of the WT projection into the latent and Nataf spaces, respectively. Each point in these plots is the centroid of the projection of a

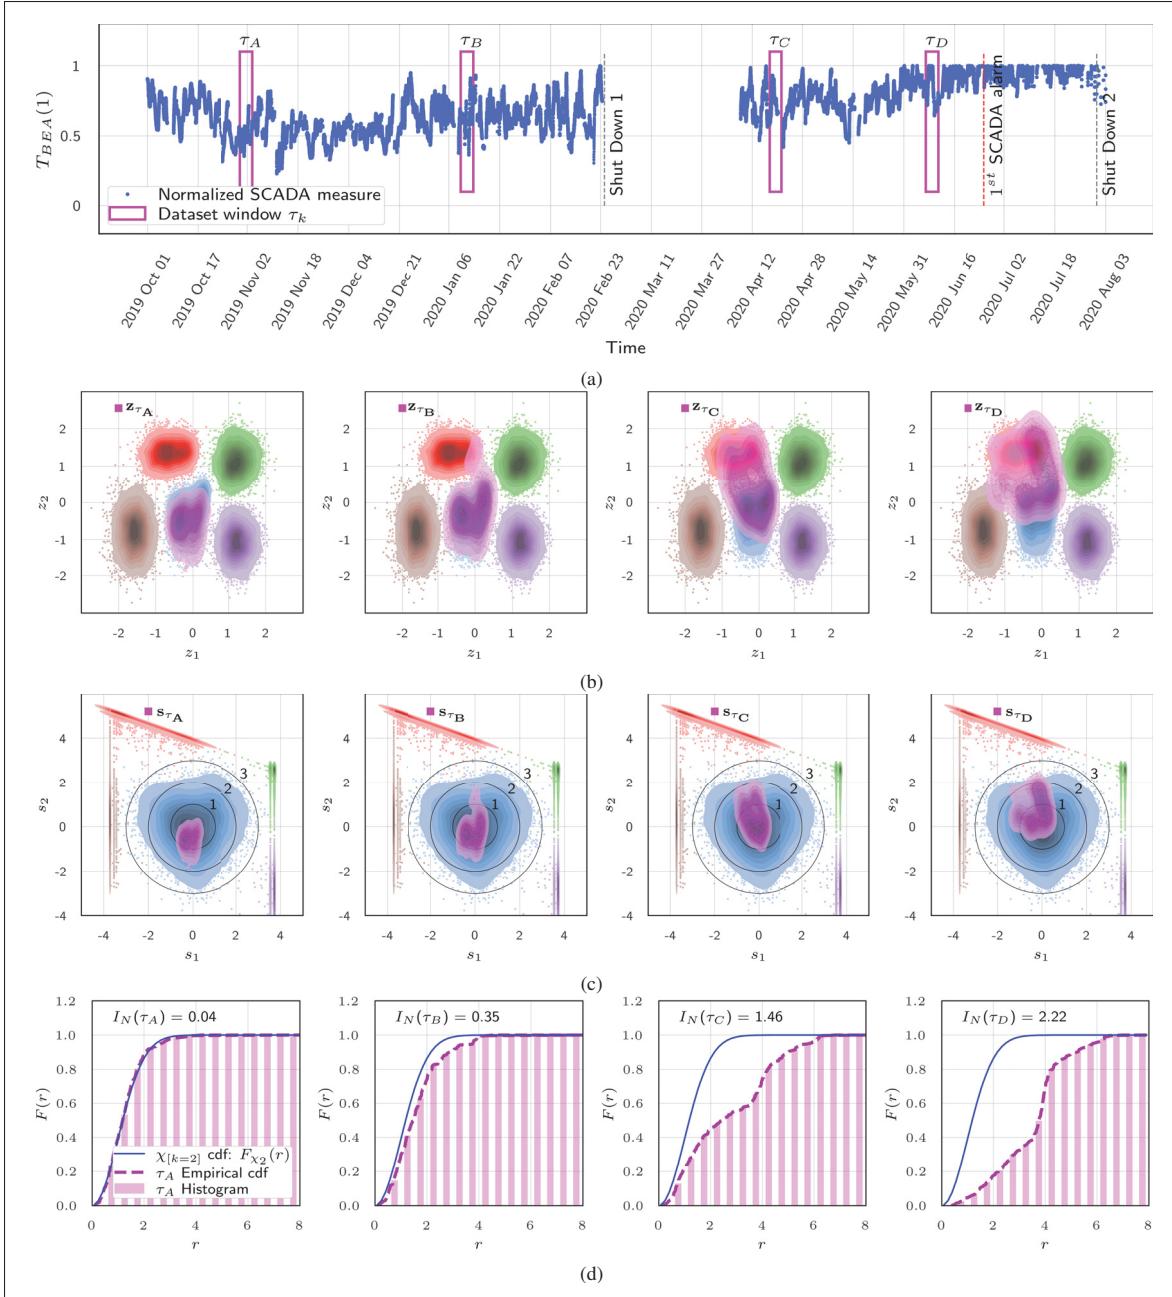
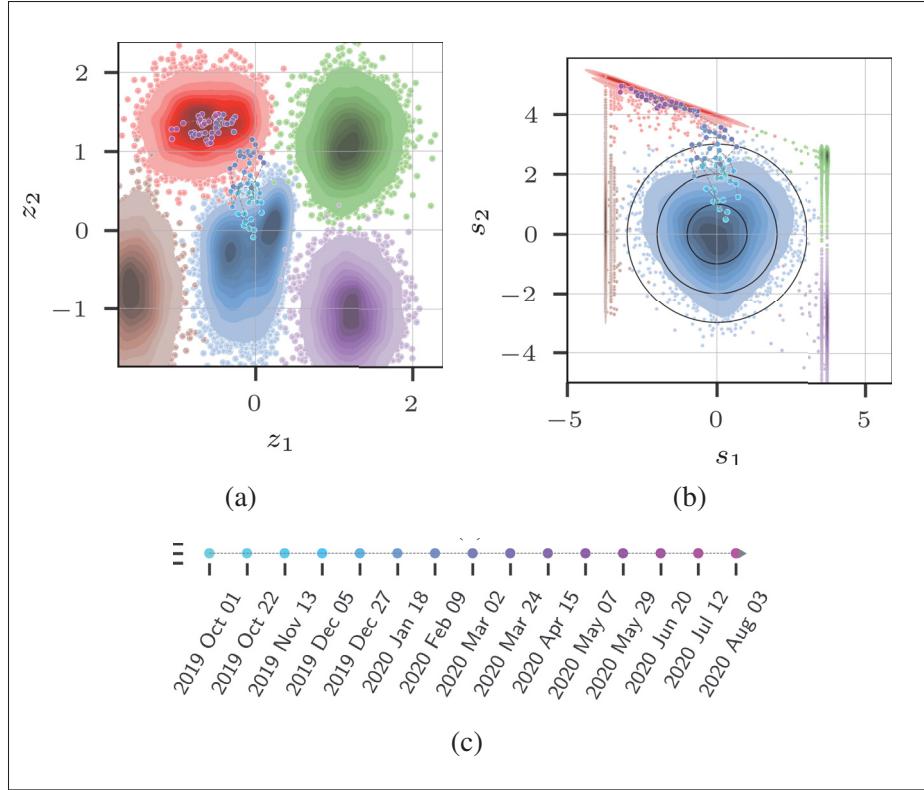


Figure 4.21 Estimation of the HI  $I_N(\tau_k)$  for 4-day periods  $\tau_k, k \in \{A, B, C, D\}$

four-day dataset. The timeline is indicated with the color map, which gives the visualization of the WT condition as a trajectory in the representation spaces. The blue cluster corresponds to the healthy HY condition and the red cluster to the BEA condition. Note that the transition from the HY cluster toward the BEA cluster is evidenced in both plots.



**Figure 4.22** Projection of the case study main bearing overtemperature as a trajectory in (a) the latent space and (b) the standard Nataf space for the (c) timeline identified by the cyan-magenta color-map

#### 4.6.6 Comparative analysis of the performance for detecting main bearing overtemperature

This section focuses on the detection of the BEA condition that raised the SCADA alarm at  $t_{BEA}^*$  and led to the WT shutdown at  $t_{Down2}$ . To evaluate the performance, Table 4.4 summarizes competing detection approaches and gives the respective detection dates for the dataset analyzed above. The approaches from (Cambron *et al.*, 2017; Oliveira-Filho *et al.*, 2022) detect main bearing degradation exclusively. In (Renström *et al.*, 2020), a classical unsupervised VAE model is used.

From Table 4.4, the anticipation obtained from the proposed approach outperforms that estimated using previous works (Cambron *et al.*, 2017; Oliveira-Filho *et al.*, 2022, 2023). The gain in

Tableau 4.4 WT main bearing overtemperature detection approaches

Detection approach reference and description	Detection date
<b>SCADA system alarm</b> (IEC, 2022) The SCADA system raises alarms based on threshold rules for the main bearing temperature.	$t_{BEA}^* = 2020/6/22$
<b>Residue of linear multivariate model</b> (Cambron <i>et al.</i> , 2017) (i) Detection of WT main bearing overtemperature based on the residue between predicted and actual daily averages of the main bearing temperature $\hat{e} = \hat{T}_{BEA} - T_{BEA}$ ; (ii) $\hat{T}_{BEA}$ is estimated from a linear multivariate model whose parameters are identified using healthy condition data; (iii) The EWMA control chart is used to detect the BEA condition.	$t_{D1} = 2020/6/21$
<b>Mahalanobis distance in the VAEC latent space</b> (Oliveira-Filho <i>et al.</i> , 2023) (i) multiple condition detection for WT combining the VAEC encoding and the Mahalanobis distance; (ii) A labeled database comprising multiple conditions is used to train the VAEC model. The VAEC encoder then projects the WT SCADA measures into a disentangled latent space; (iii) The Mahalanobis distance is used to measure the distance between the distributions in the latent space of new datasets of interest and the reference healthy condition dataset; (iv) The EWMA control chart is used to detect trends in the daily average of the Mahalanobis distance.	$t_{D2} = 2020/6/15$
<b>Approach introduced in this paper</b> (i) Multiple condition detection for complex systems combining a suitable LVM and the NT; (ii) An LVM is trained with the pertinent database such that the latent space representation comprises disentangled clusters and the reference healthy condition is well characterized; (iii) The NT is defined using the healthy cluster as reference, thus defining the standard Nataf space projection; (iv) Two HIs follow from the norm of data points projected into the Nataf space : outlier HI $I_M$ and the out-of-distribution HI $I_N$ ; the two HIs are combined to produce the system condition status.	$t_{D3} = 2020/5/22$

performance by  $I_M$  is mostly due to the use of the labeled database to train the VAEC model. This supervised training allowed to have a disentangled LVM latent space that was then mapped into the standard Nataf space. The performance of the proposed approach is further discussed in the next section.

#### 4.7 Summary and Discussion

This section summarizes and discusses the results from case studies I and II.

The success of the proposed approach in obtaining a standardized LVM representation for complex systems was evidenced within the two case studies analyzed in this paper, which used latent space representations based on supervised LVMs to achieve disentangled latent representations. The LSTM-VAE-Regression model was chosen to project the C-MAPSS FD001 dataset into a 2-D latent space. Turbofan engines in this study case were considered as healthy or degraded. For the second case study, WTs SCADA data were projected into a 2-D latent space using the VAEC model. Its supervised training used a labeled database comprising five conditions - the healthy condition plus four abnormal conditions.

It is worth noting that the VAE model alone might be sufficient to obtain a disentangled LV representation for simpler systems or systems with highly informative features. As long as the healthy condition is identified in the latent space and the LVs are not highly correlated, the NT can be defined. In most real-life complex systems, however, supervised implementations of LVM might be necessary to obtain a suitable LV representation, i.e., with disentangled clusters. The complexity of the systems analyzed in the case studies and the nature of the available measures guided the choice of supervised LVMs. Fortunately, the labels are required only in the offline phase. Once the LVM model and the NT are set, the online phase relies only on the updated features to give the condition output for the complex system being monitored.

The analysis in this paper used 2-D representation spaces ( $N = 2$ ). This setting facilitates plotting and visualization. It was shown that the resulting standard Nataf spaces verified the expected properties in both case studies. Indeed, in both cases, the healthy cluster follows the 2-D normal distribution and the norm of its points follows the  $\chi_2$  distribution. The HIs  $I_M$  and  $I_N$  were defined from the norm in the 2-D standard Nataf space. One could consider setting higher latent space dimensions if needed. For higher  $N$  values, the properties of the standard Nataf space and the definition of the two HIs are essentially the same, except for the degree of liberty  $N$  of the  $\chi_N$  distribution.

As expected, the HIs  $I_M$  and  $I_N$  gave complementary outcomes. The HI  $I_M$  allowed to detect outliers of the normal distribution. It was proven to be particularly suitable for detecting abnormal conditions evolving within a few time steps, such as the ICE condition in case study 2. In practice, the margin of action for rapidly evolving degradation modes is limited, and the detection of such events is of limited interest. Nevertheless, the HI  $I_M$  is retained in the proposed approach to ensure the robustness of the combined HI  $I_M$  OR  $I_N$ .

The two case studies revealed that the HI  $I_N$  is suitable for degradation modes evolving in the long term, and was able to detect the onset of abnormal conditions long before these conditions became critical. In the C-MAPSS FD001 engines database,  $I_N$  predicted the reference detection 12 cycles in advance, on average, whereas  $I_M$  gave results similar to the ground-truth times of degradation initiation. In the WT case study,  $I_N$  anticipated the SCADA alarm for the BEA condition in 31 days, outperforming the  $I_M$  detection and multiple competing approaches. The earlier detection of abnormal conditions by  $I_N$  is a promising result given that the longer anticipations give more time for O&M planning and interventions.

The choice of detection criteria might be adapted according to the application of interest and the accuracy and false alarm rate requirements. Moreover, a sensitivity analysis is recommended for optimal adjustments of settings such as  $\tau$  and  $\Delta_{lag}$ . The persistence criteria chosen for  $I_N$  in this paper were such that the HI focused on degradation modes evolving in the long term. That explains why no  $I_N$  alarm was raised for the rapidly evolving ICE condition in February 2020. The association of the two HIs allowed to maintain relatively simple base and persistence criteria. Regarding the detection thresholds, the results from the two case studies suggest that the definition of the threshold  $DT_M$  from the theoretical distribution  $\chi_N$  is pertinent. Indeed, the theoretical value  $DT_M = P_{99}[\chi_2] = 3.03$  is very close to the values obtained from the empirical probability distribution for healthy engines ( $DT_M = 3.1$ ) and for healthy WTs ( $DT_M = 3.0$ ). Analogously, similar  $DT_N$  values were estimated for the two case studies :  $DT_N = 1.1$  for the healthy engines and  $DT_N = 1.2$  for the healthy WTs.

The enhanced performance of the detection based on the standard Nataf space can be associated with two main aspects of the proposed approach. First, supervised learning was used in both case studies as a strategy to obtain disentangled clusters in the LVM latent spaces. In this regard, the proposed approach requires more information than the competing approaches analyzed in section 4.6.6. Second, the NT can be interpreted as a regularized zoom-in on the reference healthy condition. As a result, shifts in the original physical space are amplified in the standard Nataf space, leading to stronger indications of the onset of degradation modes.

Plots of the 2-D LVM latent space and of the standard Nataf space supported the arguments and analysis presented in this paper. It was shown that, for the C-MAPSS FD001 data, the position in the latent space is related to the level of degradation of the engine. For the VAEC latent space trained to reproduce the WT SCADA data, the position in the latent space suggested the condition to which a data point belongs. The case studies showed that the standard Nataf space preserves the capacity to visually represent the evolution of the condition of complex systems. Finally, in Figures 4.22(a) and (b), it was shown that the evolution of the system condition can be represented as a trajectory in the LV and Nataf spaces. Where the LVM latent space identifies multiple conditions, that can potentially provide diagnosis information since abnormal points move toward the corresponding abnormal condition clusters. Exploring this aspect, as well as a quantitative assessment of the improvements in interpretability, represents potential avenues for future research.

#### **4.8 Conclusion**

This work addressed the LVM-based representation of complex systems. The main contribution of this paper is the introduction of a standardized latent space representation for complex systems by using the Nataf isoprobabilistic transform. It was shown that, contrary to the highly variable LVM representation, the standard Nataf space preserves the probability distribution of the healthy condition, namely, the multivariate normal distribution. The proposed CM framework can be applied to a variety of complex systems. This versatility was demonstrated within two case studies covering distinct technological domains.

The standardization of the LVM representation allows to compare representation spaces corresponding to multiple assets. Most importantly, two HIs,  $I_M$  and  $I_N$ , were defined from the characterization of the standard Nataf space. The proposed approach combines the two HIs to achieve robust detection.  $I_N$  allows to detect the onset of abnormal conditions significantly earlier than competing approaches. Complementarily,  $I_M$  is a point-wise HI that captures degradation modes evolving within a few time steps. For example, in case study 2,  $I_M$  detected ice accretion on blades, which was not detected by  $I_N$ . The two case studies demonstrated the performance and potential of the proposed detection approach.

As a secondary contribution, this paper introduced two examples of applications for the emergent field of interpretability of DNN models. For instance, the two case studies illustrate how the LVM latent spaces and the standard Nataf space can be used to visually represent the evolution of complex systems. These visualizations complement the condition status information and can, therefore, enhance the interpretability and trust of the outcomes among O&M analysts and practitioners.

**Acknowledgment** The authors acknowledge Power Factors for providing the database used in the work.

## CHAPITRE 5

### REMAINING USEFUL LIFE ESTIMATION BASED ON VARIATIONAL AUTOENCODER LATENT SPACE REPRESENTATION : APPLICATION TO WIND TURBINES

Adaiton Oliveira-Filho<sup>1</sup>, Ryad Zemouri<sup>2</sup>, Francis Pelletier<sup>3</sup>, Antoine Tahan<sup>1</sup>

<sup>1</sup> Department of Mechanical Engineering, École de Technologie Supérieure, 1100 Rue Notre Dame O, Montréal, QC H3C 1K3, Canada;

<sup>2</sup> Research Center of Hydro-Québec, 1800 Bd Lionel-Boulet, Varennes, QC J3X 1S1, Canada;

<sup>3</sup> Power Factors, 7005 Boulevard Taschereau, Brossard, QC J4Z 1A7, Canada.

Article soumis pour publication à la revue « IEEE Transactions on Reliability » le 14 avril 2024.

**Abstract :** This paper introduces a novel approach for estimating complex systems' RUL using the latent space representation derived from a LVM. LVMs allow for projecting high-dimensional physical spaces comprising the measures from complex systems into low-dimensional latent spaces. Applications from multiple study domains demonstrate that the latent space from appropriate LVMs represents the system's health condition. The projection of time-oriented datasets in the latent space produces trajectories that inform about the evolution of the system condition over time. A kinematic modelling and an appropriate regularization allow for describing the latent space projection as a smooth trajectory. This work introduces a RUL estimator based on the trajectory description by combining the Taylor expansion and the Monte Carlo method. The proposed approach is demonstrated through three case studies on WT operation using data from the SCADA system. Results show a strong correlation between the predicted and ground-truth RUL. This prognosis model has the potential to support predictive maintenance strategies for WT, which can contribute to reducing O&M expenditures while increasing reliability and availability.

**Keywords :** prognosis, latent space representation, remaining useful life, Monte Carlo.

#### 5.1 Introduction

The recent PHM literature utilizes a wide range of AI models (Zio, 2024; Zhao *et al.*, 2021b; Nguyen, Medjaher & Tran, 2023). One major limitation of the deployment of AI-based models in

industrial contexts is the lack of explainability (Cummins *et al.*, 2024). One strategy to overcome such limitation is using visualization tools embedded in the definition of the AI models (Zemouri *et al.*, 2019). In particular, the VAE model (Kingma & Welling, 2014) architecture comprises a low-dimension space referred to as the latent space.

The introduction of the VAE model by Kingma and Welling in the pivotal work (Kingma & Welling, 2014) was followed by multiple variations of the VAE, which we refer to as Latent Variable Models (LVMs) (Tschannen *et al.*, 2018). The latent variables capture the main characteristics of the input variables.

Applications from multiple domains show that the latent space gives information on the health state of the system of interest (Tschannen, Bachem & Lucic; Zemouri *et al.*, 2019). LVMs have been effectively used in the PHM literature to perform condition monitoring, early detection, diagnosis, and prognosis of complex systems (Shahid & Ghosh, 2019). Some application domains verifying such conditions include the turbofan engines described by the C-MAPSS database (Costa & Sánchez, 2022), machining quality described by multiple-sensor data (Proteau, Tahan, Zemouri & Thomas, 2023), Wind Turbine (WT) operation described by the Supervisory Control and Data Acquisition (SCADA) system measures (Oliveira-Filho *et al.*, 2024), etc.

In (Shahid & Ghosh, 2019), an Autoencoder based on a Recurrent Neural Network is used to project the temporal evolution of complex systems into a smooth trajectory that reflects the transition from healthy condition to failure. The corresponding latent space allowed for defining an interpretable RUL estimator. The demonstration with the C-MAPSS database (Ramasso & Saxena, 2014) revealed good performances for multiple turbofan run-to-failure time series.

In (Costa & Sánchez, 2022), the VAE model was combined with a regressive DNN. The corresponding latent space is such that run-to-failure datasets from the C-MAPSS database project as linear trajectories, in contrast with highly irregular trajectories from the implementation without the regressive DNN. This model gave accurate predictions of the RUL function, and the latent space is a suitable visualization tool to explain the RUL estimation.

Proteau *et al.* (2023) also used the combination of a VAE-encoder and a regression-DNN. The authors analyzed data from machined workpieces in an industrial context and used the proposed model to predict the geometric dimensioning and tolerancing quality. Data from conforming machining processes are projected in a specific region of the latent space. Once the process is perturbed, the nonconformity is projected as points going far from the healthy region. Even if the concept of trajectory was not explicitly exploited, the projection of datasets from a degrading machining process clearly defines smooth trajectories in the latent space.

A supervised implementation of the VAE model embedding a classification DNN allowed Oliveira-Filho *et al.* (2023, 2024) to project the WT high-dimensional physical space of SCADA measures into a 2-D latent space. VAEC latent space is appropriate to analyze and visually represent the WT health condition.

Previous works suggest that the projection of time-oriented datasets in the latent space allows for following the evolution of the system condition within time. Nevertheless, descriptions of the projected datasets are incomplete, and the literature lacks analyses derived from the trajectory descriptions themselves.

In this context, this work aimed at introducing a general description of the trajectories corresponding to the projection of points in the latent space. It then defines a RUL estimation approach from such a description.

The proposed approach is demonstrated in the RUL estimation of WT using data from the SCADA system. The PHM analysis of WT is a very active study domain given the potential to enhance these system's reliability and availability while reducing the O&M expenditures (Santiago *et al.*, 2024; Badihi *et al.*, 2022; Rezamand *et al.*, 2020a).

The main contributions of this paper are summarized as follows :

1. The original contribution of the present work is to introduce a general approach to describe the projection of time-oriented datasets in the latent space as smooth trajectories. Such

a description is then combined with the Taylor expansion and the Monte Carlo method in the definition and a simple yet effective estimator of the RUL pdf.

2. The RUL estimation depends strongly on the definition of the end-of-life. A multiple-level criterion is introduced in the latent space, allowing for the personalization of the proposed approach according to the application domain characteristics and reliability requirements.
3. The proposed approach is implemented in the RUL estimation of a real-life case study of WT degradation using data from the SCADA system.

The remainder of this paper is structured as follows : Section 5.2 describes the latent variable models for complex systems ; Section 5.3 presents the framework of the PHM analysis based on the latent space representation ; Section 5.4 applies the proposed prognosis approach to the estimation of the RUL of wind turbines given different modes of degradation. Finally, section 5.5 concludes this paper.

## 5.2 Latent Space Representation of Complex Systems

Section 5.2.1 briefly presents the Latent Variable Models, then section 5.2.2 focuses on the LVM for representing complex systems operating at multiple conditions. Section 5.2.3 introduces the trajectory description of the system from the latent space.

### 5.2.1 Latent Variable Models

Assume the complex system  $\mathcal{S}$  is described by  $n_P$  physical measures. Analyzing the behaviour and condition in such a high-dimensional and often intricate physical space is a difficult task. The VAE model allows for projecting a high-dimensional space into a low-dimensional latent space that preserves the main features from the original system description. Let  $n_L$  be the latent space dimension,  $n_L < n_P$ .

The VAE comprises two key DNN functions, namely the encoder and the decoder. Let  $\mathbf{x} \in \mathbb{R}^{n_P}$  be a data point in the physical space and  $\mathbf{z} \in \mathbb{R}^{n_L}$  be a data point in the latent space. The encoder is defined as the mapping  $f_\phi : \mathbf{x} \mapsto \mathbf{z}$  and the decoder is defined as the mapping  $g_\theta : \mathbf{z} \mapsto \tilde{\mathbf{x}}$ . The

VAE training includes the minimization of a loss function that combines the reconstruction loss  $\mathcal{L}_{RE}$  and the Kullback-Liebler loss function  $\mathcal{L}_{KL}$ . While  $\mathcal{L}_{RE}$ , which can be set as the  $L_2$  norm or the mean-squared error  $\mathcal{L}_{RE} = \frac{1}{2}\|\mathbf{x} - \tilde{\mathbf{x}}\|_2^2$ , for example, forces the latent variables to capture the main relevant characteristics from the physical space, the  $\mathcal{L}_{KL}$  loss influences the distribution and regularization of the latent space.

LVM models are variations of the VAE model built using the structure of a latent space representation. In particular, in (Oliveira-Filho *et al.*, 2023), a supervised implementation of the VAE model, the VAEC, was introduced to project the high-dimensional physical space of measures from the SCADA system into a low-dimension and disentangled space. The VAEC consists of a classical VAE model embedded with a Classifier DNN which input is the latent variable and the output is set with the Softmax activation function and dimension  $n_C$  corresponding to the classes of conditions.

### 5.2.2 Latent Space Representation of Systems Operating at Multiple Conditions

The complex system is supposed to operate at one of  $n_C$  conditions, one healthy condition and degraded conditions of interest. In the high-dimensional physical space, let  $\mathbb{X}_k, k \in \{1, \dots, n_C\}$ , be the datasets of points  $\mathbf{x} \in \mathbb{R}^{n_P}$  belonging to the  $n_C$  classes of condition. Once the LVM is trained with the labelled database, the encoder projects these datasets  $\mathbb{X}_k$  into clusters of points in the latent space  $\Omega_k \subset \mathbb{R}^{n_P}, k \in \{1, \dots, n_C\}$ . Fig. 5.1 illustrates a VAE-based 2-D latent space projection of a system with  $n_C = 6$ .

The latent space manifold can be associated with labels to define a classifier based on the latent space position. This classifier can then be used to identify classes corresponding to newly projected points.

The degradation of the complex system corresponds, in the latent space, to the transition of projected points from a healthy cluster to a degraded cluster. Multiple examples of such patterns can be found in the literature (Shahid & Ghosh, 2019; Costa & Sánchez, 2022; Proteau *et al.*, 2023; Oliveira-Filho *et al.*, 2024).

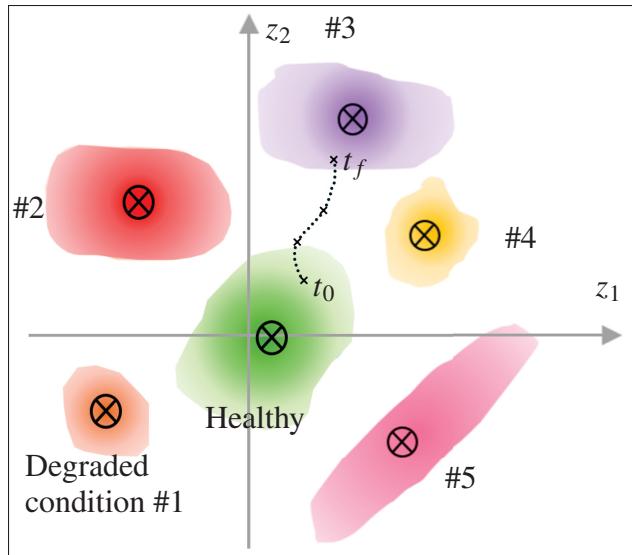


Figure 5.1 Complex system 2-D  
latent space representation,  
 $\otimes$  = Centroid position

### 5.2.3 System Degradation as a Trajectory in the Latent Space

The projection of time series from the physical space allows for following the evolution of the system in the latent space within time. This is particularly useful to monitor the occurrence and the pattern of degradation modes.

Let  $\mathbf{x}_{t_k} \in \mathbb{R}^{n_P}$  be data points in the physical space measured at the discrete time instants  $t_k \in \{t_0, t_1, \dots\}$ . The encoder allows for projecting these data points in the latent space as the points  $\mathbf{z}_{t_k} \in \mathbb{R}^{n_L}$ .

The scope of the present work is limited to degradation modes verifying the following assumptions :

- Degradation modes are irreversible. Once the trajectory leaves the healthy condition and enters a degraded condition cluster, the system is expected to remain in this class of condition ;
- Disjoint degradation conditions. In case of degradation, the system degraded to one class of condition. This is eventually the most probable or the most critical between the two conditions.

- The degradation is slow, that is, it happens within multiple time steps. This assumption excludes unpredictable abrupt transitions ;

When degradation modes meet such conditions, the latent space projection of time-oriented datasets can be described by trajectories in the latent space. The pattern of such trajectories depends on the system properties and the time step of the measured time series.

One can define a trajectory approximation using a suitable regularization approach. Examples of suitable approaches are Moving Average (MA), exponentially weighted moving average, Weighted Polynomial Regression (WPR), and AI-based models. Let  $t \mapsto \mathbf{z}(t) = [z_1(t), \dots, z_{n_L}(t)]$ ,  $\mathbb{R} \rightarrow \mathbb{R}^{n_L}$ , be the multivariate time function that describes the trajectory of the system in the latent space with independent coordinates  $z_i(t)$ .

For the sake of definition of the trajectory predictor further in this paper, the functions  $z_i(t)$ ,  $i \in \{1, \dots, n_L\}$ , are supposed to be differentiable up to order  $m$  at all  $t \in [t_0, t_f]$ , the period of interest. This allows for defining a kinematic description of the trajectory given by the time derivatives, including the first order time derivative (velocity)  $\mathbf{v}(t) \in \mathbb{R}^{n_L}$  and the second order time derivative (acceleration)  $\mathbf{a}(t) \in \mathbb{R}^{n_L}$ . The trajectory corresponding to the degradation of the system from healthy to condition #3 within the period  $[t_0, t_f]$  is illustrated in Fig. 5.1.

### 5.3 A general framework for prognosis based on the latent space representation

Section 5.3.1 describes the prognosis in the framework of PHM analysis. In the prognosis step, the RUL estimation combines two complementary tasks, namely prediction and classification. Section 5.3.2 describes the prediction of smooth latent space trajectories and section 5.3.3 describes the classification based on the latent space position. The actual estimation of the RUL value and distribution is the subject of section 5.3.4.

### 5.3.1 The PHM Analysis

Gouriveau, Medjaher & Zerhouni (2016) describe the PHM analysis as a cycle comprising successive steps : (1) data acquisition, (2) data treatment, (3) detection, (4) diagnosis, (5) prognosis, (6) decision support, and (7) human-machine interface. The detection of an abnormal condition is an early step of the PHM analysis. Once an abnormal condition is detected, the diagnosis determines the most probable condition. The prognosis step in the PHM analysis consists of estimating the RUL for the abnormal condition that was previously detected and diagnosed. The RUL is defined as the period between the predicted End-Of-Life (EOL) instant  $t_{\text{EOL}}$  and the current time instant  $t_C$ , as given by Eq. 5.1 :

$$\text{RUL} = t_{\text{EOL}} - t_C \quad (5.1)$$

The prognosis supports operators on decisions around the O&M, e.g., planning in situ interventions such as inspections and repairements, as well as the managing required material and human resources (Chebel-Morello, Nicod & Varnier, 2017b).

This paper implements the PHM analysis on WT based on their latent space representation. The diagram in Fig. 5.2 presents the steps of the proposed PHM analysis.

### 5.3.2 Latent Space Trajectory Predictor Using Taylor Expansion

Let  $t = t_0$  be the instant when an abnormal condition is detected. Let  $t \mapsto z_i(t)$ ,  $i \in \{1, \dots, n_L\}$ ,  $t > t_0$ , be the latent space coordinates describing the trajectory in the latent space. We assume these latent variables are continuous and differentiable up to order  $m \geq 3$  around  $t = t_0$ . Under such conditions, each position function  $z_i(t)$  can be approximated to the second order using the Taylor expansion, as given by Eq. 5.2 :

$$\hat{z}_i(t) = z_i(t_0) + v_i(t_0)(t - t_0) + \frac{1}{2}a_i(t_0)(t - t_0)^2 \quad (5.2)$$

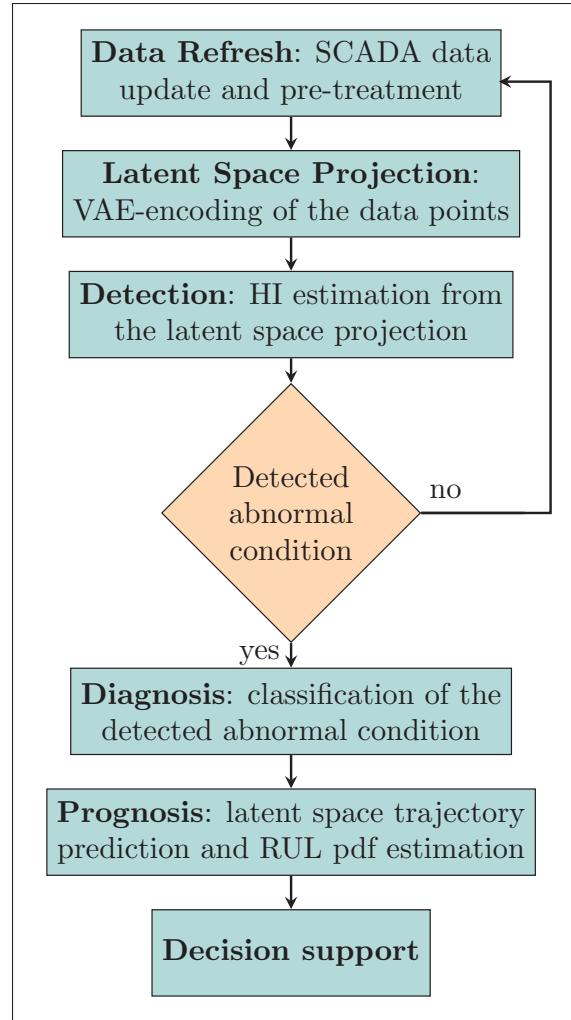


Figure 5.2 PHM analysis based on the latent space projection

and the absolute error of the Taylor approximation is given by Eq. 5.3 :

$$\Delta_{zi}(t) = \left| \delta z_i + \delta v_i \Delta t + \delta a_i \frac{\Delta t^2}{2} + \sum_{k=3}^m \frac{\Delta t^k}{k!} \frac{d^k z_i}{dt^k}(t_0) \right| \quad (5.3)$$

where  $\delta z_i$ ,  $\delta v_i$ , and  $\delta a_i$ ,  $i \in \{1, \dots, n_L\}$ , are the dispersion on position, velocity, and acceleration, respectively ;  $\Delta t = t - t_0$  ; and  $m \geq 3$  is the higher order of the derivative for the error estimation. It is recommended to estimate multiple derivatives of the trajectory coordinates and choose  $m$

accordingly ( $m = 3$  should be sufficient for most applications). Fig. 5.3 illustrates the Taylor expansion approximation for two intervals  $\Delta t$  with the respective error bars for a 2-D latent space.

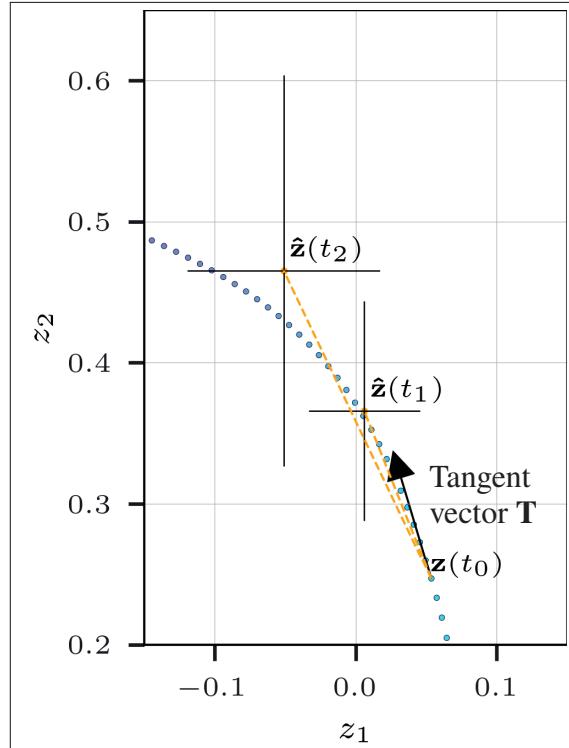


Figure 5.3 Trajectory prediction given the initial position  $\mathbf{z}(t_0)$

### 5.3.3 Considerations of the End of Life Criteria

The RUL estimation is based on the definition of a criterion to establish when the system reaches the EOL. The criteria defining the EOL depend strongly on the application domain and on the specific degradation mode. For instance, in safety-critical application domains with high-risk processes or high-cost assets, failure should be avoided at all costs. Nuclear energy and aeronautics are two of such critical systems (Zio, 2022; Zhou *et al.*, 2023). In these cases, the end-of-life should be set as a end of safe operational life, and the margin for operating in abnormal condition is tiny. For some systems, the operation under degraded condition is acceptable, but failure remains costly, thus it should be avoided. Thus, rather than catastrophic

failure, the EOL where the operation would be critically damaging to the WT system. This is the case for wind turbines (Le & Andrews, 2016), as further discussed in section 5.4.2. Finally, for systems which failure occurrences have low impact and costs, the degradation and failure are acceptable. Curative maintenance strategies would be adequate for such systems (Gouriveau *et al.*, 2016).

In the latent space representation, the EOL criterion can be defined as a subset of the latent space. This allows for defining a binary classifier that identifies whether the system is degraded but still operational or reached the EOL.

To provide the latent space with EOL criterion that can be adapted according to the application domain, we introduce three curves in the latent space : Let  $\Gamma_{D1} \subset \mathbb{R}^{nL}$  be a closure for the healthy condition, for example the region in the latent space enclosing a percentile  $P_1$  of all data points, e.g.,  $P_1 = 99\%$ ; Let  $\Gamma_{D2} \subset \mathbb{R}^{nL}$  be the curve that separates the latent space in two regions. For example, one can use a Gaussian Mixture Model (GMM) trained with two Gaussian kernels, and then use this classifier to define the two regions in the latent space ; Let  $\Gamma_{D3} \subset \mathbb{R}^{nL}$  be the curve enclosing the degraded condition, for example the region in the latent space enclosing a percentile  $P_3$  of all data points, e.g.,  $P_3 = 50\%$ .

The EOL curve  $\Gamma_{EOL} \subset \mathbb{R}^{nL}$  can then be defined as one of the curves among  $\Gamma_1$ ,  $\Gamma_2$  and  $\Gamma_3$ . Table 5.1 summarizes the definition of such curves.

Tableau 5.1 Transition curves in latent space with respective actions and thresholds

<b>Curve</b>	<b>Transition</b>	<b>Action</b>	<b>Threshold</b>
$\Gamma_{D1}$	From healthy to incipient degradation	Careful monitoring	$P_{95}$ enclosure of healthy cluster
$\Gamma_{D2}$	Enters degraded condition region	Take prompt action	GMM-based classifier
$\Gamma_{D3}$	Reaches end-of-life (RUL = 0)	Shut-down	$P_{50}$ enclosure of degraded cluster

### 5.3.4 RUL Estimation

Let the function *condition\_classifier* be a binary classifier that identifies whether the system is still operational (in degraded condition) or reached the EOL. First, we are interested in the central RUL estimation based simply on the Taylor expansion. Algorithm 5.1 associates the trajectory predictor with the latent space classifier to estimate the central RUL value.

Algorithme 5.1 Central RUL estimation

**1 Algorithme : Central RUL estimation**

**Input :** Latent space classifier *condition\_classifier*; Trajectory function  $\mathcal{T} = \{\mathbf{z}(t) = [z_1(t), z_2(t)], t \in [t_0, t_n]\}$ ; Predictor *trajectory\_predictor*; time step  $\delta t$ .  
**Output :** Remaining useful life *RUL*.

```

2 Actual_condition ← condition_classifier( $\mathbf{z}(t = t_n)$ );
3 if Actual_condition == "EOL" then
4   | return RUL ← 0;
5 end if
6 else
7   |  $t_i \leftarrow t_n$ ;
8   | while True do
9     |   |  $t_i \leftarrow t_i + \delta t$ ;
10    |   |  $\mathbf{z}_{ti} \leftarrow trajectory\_predictor(\mathcal{T}, t_i)$ ;
11    |   |  $t_i\_condition \leftarrow condition\_classifier(\mathbf{z}_{ti})$ ;
12    |   | if  $t_i\_condition == "EOL"$  then
13      |     | return RUL ←  $t_i - t_n$ ;
14    |   | end if
15   | end while
16 end if

```

Nevertheless, the RUL value should reflect the randomness from the WT operation and the uncertainties from the latent space modelisation. For that sake, one can introduce randomness in the trajectory prediction in coherence with the estimated absolute errors  $\Delta_{zi}(t)$ . To characterize the RUL probability distribution, a random component is included in the trajectory predictor. The trajectory predictor function *trajectory\_predictor\_rand* is defined so that it takes the central value plus a random perturbation  $\epsilon_i \sim \mathcal{N}(0, \sigma_i^2)$ . The random perturbation  $\epsilon$  relates to the

estimated absolute errors by  $\sigma_i = \Delta z_i / 3$  to ensure coverage of 99.7% of the normal distribution's range. For coherence with the irreversibility assumption, a random perturbation must verify  $\epsilon \cdot \mathbf{T} \geq 0$ , which is imposed with Eq. 5.4, where  $\mathbf{T}$  is the vector tangent to the trajectory :

$$\mathbf{z}^\epsilon = \begin{cases} \mathbf{z} + \epsilon, & \text{if } \epsilon \cdot \mathbf{T} \geq 0 \\ \mathbf{z} & \text{otherwise} \end{cases} \quad (5.4)$$

Then, the Monte Carlo approach is used to characterize the RUL probability distribution. First,  $N \gg 1$  independent RUL estimations are performed considering the trajectories with random perturbations, as depicted in Fig.5.4.

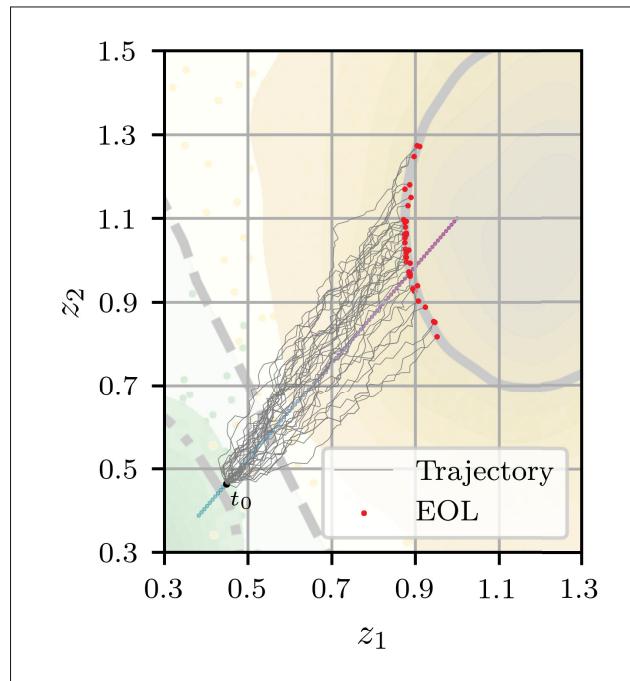


Figure 5.4 Samples of run-to-failure trajectories in the latent space

Then, the RUL distribution is estimated by using a Kernel Density Estimator (KDE) (Silverman, 2018) on all independent RUL estimations. This approach is presented in Algorithm 5.2.

Algorithme 5.2 RUL pdf estimation

**1 Algorithme : RUL pdf estimation**

**Input :** Latent space classifier *condition\_classifier*; Trajectory function  $\mathcal{T} = \{\mathbf{z}(t) = [z_1(t), \dots, z_{n_C}(t)], t \in [t_0, t_n]\}$ ; Stochastic predictor *trajectory\_predictor\_rand*; Number of samples  $N$ ; Time step  $\delta t$ .

**Output :** Estimated RUL pdf.

```

2 RUL  $\leftarrow$  [];
3 for  $k = 1$  to  $N$  do
4   condition  $\leftarrow$  condition_classifier( $\mathbf{z}(t = t_n)$ );
5   if condition == "EOL" then
6     RUL.append(0);
7     continue;
8   end if
9    $t_i \leftarrow t_n$ ;
10  while True do
11     $t_i \leftarrow t_i + \delta t$ ;
12     $\mathbf{z}_{ti}^\epsilon \leftarrow$  trajectory_predictor_rand( $\mathcal{T}, t_i$ );
13    ti_condition  $\leftarrow$  condition_classifier( $\mathbf{z}_{ti}^\epsilon$ );
14    if ti_condition == "EOL" then
15      RUL.append( $t_i - t_n$ );
16      break;
17    end if
18  end while
19 end for
20 Estimate the pdf of RUL using KDE;
21 return Estimated RUL pdf;
```

## 5.4 Wind Turbine Prognosis Based on the Latent Space Representation

This section applies the proposed RUL estimation approach to Wind Turbines (WTs).

WTs are among the central technological solutions in the fight against climate change. These energy conversion systems are forecast to contribute significantly to the decarbonization of the energy sector (IEA, 2023; Bouckaert *et al.*, 2021; DNV, 2022b). Appropriate WT O&M strategies are paramount in this context. In particular, predictive maintenance is projected to provide higher reliability, availability, and profitability to the wind energy sector compared to

currently used preventive strategies (Chebel-Morello *et al.*, 2017b; May *et al.*, 2015; Gouriveau *et al.*, 2016). The RUL function serves as the foundation for predictive maintenance strategies.

First, section 5.4.1 describes the WT SCADA data and the VAEC model, the LVM that allowed for projecting the SCADA data as disentangled clusters in the latent space. Then, section 5.4.2 presents the EOL criteria for the WT operation. Section 5.4.3 demonstrates the proposed approach with synthetic case studies to showcase the capabilities of the proposed approach. Finally, section 5.4.4 presents the regularization method used to obtain a trajectory description from the projection of SCADA data points and demonstrates the proposed approach with the case study of a degrading main bearing.

#### **5.4.1 Latent Space Representation of Wind Turbines**

Modern WTs embed the SCADA system, which typically comprises over 50 measuring channels, including geometric, kinematic, electrical, and thermic physical measures. The SCADA data are stored in the 10-minute concentration format, where each data point is the average over 10 minutes of operation (Pandit *et al.*, 2022).

Modeling and predicting the health condition of WT is a complex task due to the high complexity of WT systems, the stochastic nature of wind, and the non-linear relations between its variables. Moreover, structural characteristics and dimensions are hardly ever accessible due to confidentiality constraints. Hence, data-based models are the most common in the literature of WT PHM.

The ever-increasing SCADA databases create a vast corpus for AI approaches. For instance, AI models can capture subtle relations between variables from a high-dimensional physical space defined by the SCADA measures. Not surprisingly, AI models gained popularity in the past decades among WT PHM publications (Zhao *et al.*, 2021b).

The latent space representation of wind turbines from the measured data is analyzed in previous works by the authors of this paper (Oliveira-Filho *et al.*, 2023, 2024). These works justify

the choice of the eleven SCADA measures listed in Table 5.2 to describe the WT condition. The analysis comprises four abnormal conditions : main bearing overtemperature, gearbox oil overtemperature, generator overtemperature, and ice accretion on blades.

Tableau 5.2 SCADA measures with the respective lower (LB) and upper (UB) bounds

Measure (Unit)	Description	LB	UB
$WS$ (m/s)	Wind speed	0	31
$n_{ROTOR}$ (rpm)	Rotor speed	0	18
$P$ (kW)	Active power	0	2000
$T_{AMB}$ ( $^{\circ}$ C)	Ambient Temp.	-25	45
$T_{NAC}$ ( $^{\circ}$ C)	Nacelle Temp.	-20	70
$T_{BEA}$ ( $^{\circ}$ C)	Main Bearing Temp.	-20	70
$T_{GBX-BEA}$ ( $^{\circ}$ C)	Gearbox Bearing Temp.	0	100
$T_{GBX-OIL}$ ( $^{\circ}$ C)	Gearbox Oil Temp.	0	100
$T_{GEN1}$ ( $^{\circ}$ C)	Generator Temp. Pos. 1	-10	140
$T_{GEN2}$ ( $^{\circ}$ C)	Generator Temp. Pos. 2	-10	140
$T_{GEN-COOL}$ ( $^{\circ}$ C)	Generator Cooling Temp.	-10	120

The classical VAE model (unsupervised) was not sufficient to disentangle clusters from different conditions in the latent space. Thus, the VAEC model was used to project the WT SCADA data into a disentangled latent space. The labelled database required to train such a model was created using three sources of data, namely SCADA measures, SCADA log files indicating alarms, and O&M reports. The procedure to build the labelled database consisted of three main steps :

**Step 1** : From the SCADA log files, identify the main abnormal conditions ; Select the datasets (WT identifier and time period) for which the SCADA system identifies abnormal conditions.

**Step 2** : Analyze each dataset to select the range of data that represents the abnormal condition of interest ; The retained dataset is often larger than the dataset defined with SCADA alarms only ;

**Step 3** : To create the database representative of the overall WT behaviour, merge datasets from same-model WTs operating under similar operational conditions.

Fig. 5.5 depicts the selection of a dataset corresponding to the condition gearbox oil overtemperature (GBX). Notice that the extended dataset contains more points than the set of SCADA exceptions.

In each case, the choice was guided by the local analysis of the variation of the main measures for each condition, e.g.,  $T_{GBX-Oil}$  analyzed for the GBX condition. Refer to the paper (Oliveira-Filho *et al.*, 2023) for further details on the creation and labelling of the database.

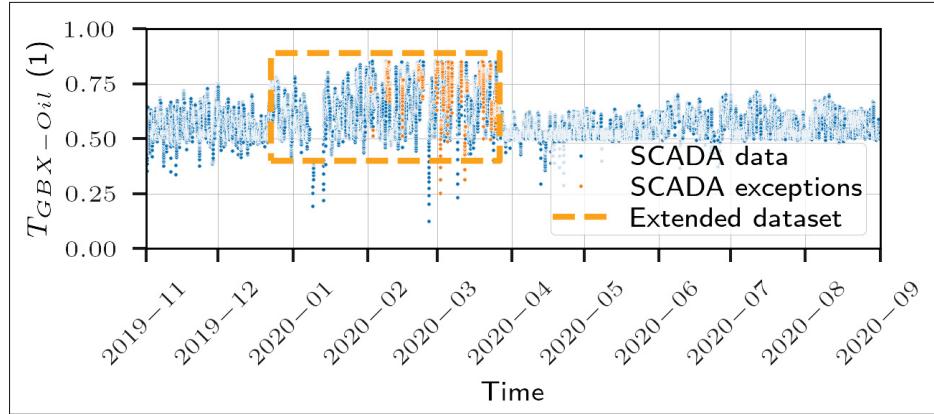


Figure 5.5 Example of the procedure to build labelled datasets using SCADA measures and log files

Table 5.3 summarizes the datasets comprising the WT condition database. The 2-D latent space projection of the WT database using the VAEC model is reproduced in Fig. 5.6.

Tableau 5.3 Labelled Database

ID	Dataset	Main Measure	Size*	Degradation
HY	Healthy	WS and $P$	10,000	No
BEA	Main bearing overtemperature	$T_{BEA}$	5,000	Yes, often
GEN	Generator overtemperature	$T_{GEN}$	5,000	Yes, often
GBX	Gearbox oil overtemperature	$T_{GBX-Oil}$	5,000	Sometimes
ICE	Ice accretion on blades	WS and $P$	5,000	No, reversible

\* Size in data points.

Abnormal conditions can be detected using the early detection approaches introduced in (Oliveira-Filho *et al.*, 2023, 2024). Once a degraded condition is detected and diagnosed, the prognosis analysis is focused on the evolution from the incipient degraded condition until the EOL. The next section characterizes such transition and introduces the EOL criteria.

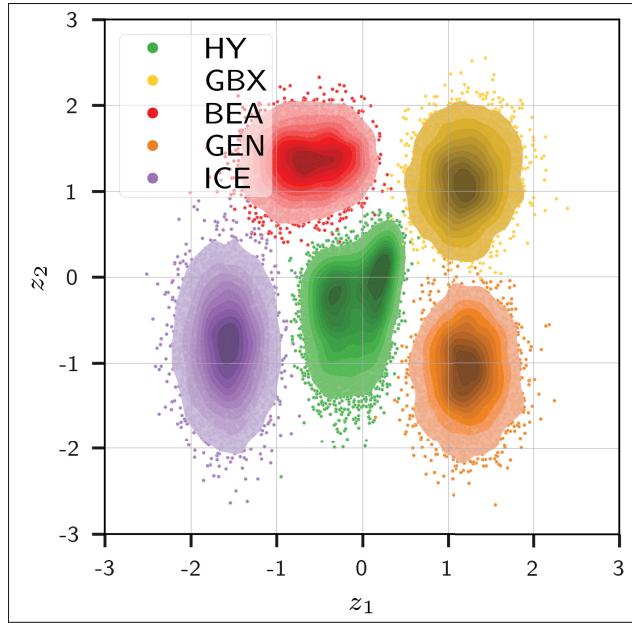


Figure 5.6 Latent space projection of the wind turbine database

#### 5.4.2 Characterizing of WT EOL in the Latent Space

WTs are usually kept operational when incipient abnormal conditions and potential degradation modes are detected (Le & Andrews, 2016). Alternatively, operators can curtail the WT to decrease the rate of degradation while still harnessing electricity (Khazaeli Moghadam, Gao, Chabaud & Chapaloglou, 2024). This is because the complete shutdown of WTs implies losses of production and the fact that prompt interventions are hardly ever possible due to security and logistical constraints. Therefore, for the most common degradation modes, the EOL can be set as an advanced stage of degradation.

We thus set the WT's EOL curve in the latent space as the curve  $\Gamma_{D3}$  enclosing 50% of the data points from the degraded dataset. Fig. 5.7(a) depicts the  $\Gamma_{EOL}$  curve in the latent space of a wind turbine assuming the GBX condition was detected. For reference,  $\Gamma_{D1}$  and  $\Gamma_{D2}$  are also plotted. Fig. 5.7(b) depicts the latent space highlighting the clusters corresponding to the HY and the BEA conditions, and shows the curves  $\Gamma_{D1}$ ,  $\Gamma_{D2}$  and  $\Gamma_{EOL}$ .

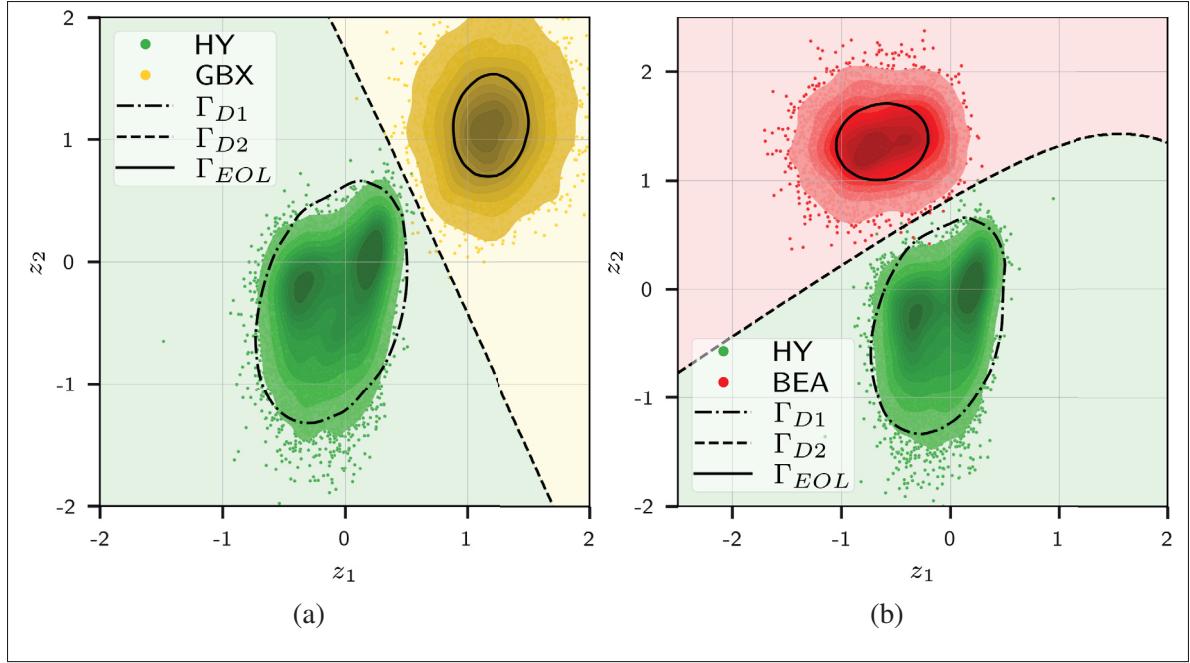


Figure 5.7 Latent space degradation curves for clusters HY and (a) GBX, (b) BEA

It is worth noticing that not all abnormal conditions characterize degradation modes. For instance, the ice accretion on blades is not a degradation because it is reversible.

### 5.4.3 Demonstration With Synthetic Trajectories

Two synthetic trajectories are introduced in this section to demonstrate the proposed approach. In both cases, it is assumed that the WT operated at the abnormal condition GBX.

#### 5.4.3.1 Linear Trajectory

Fig. 5.8 depicts a linear degradation trajectory from the HY cluster to the GBX cluster. The trajectory intersects  $\Gamma_{EOL}$  at the instant  $t_{EOL} = 78$ , which allows for estimating the ground-truth RUL function.

Fig. 5.9 gives the RUL pdf estimation at multiple instants of the operational lifetime. The linear approximation is exact for the linear trajectory, and the estimated central RUL values superpose

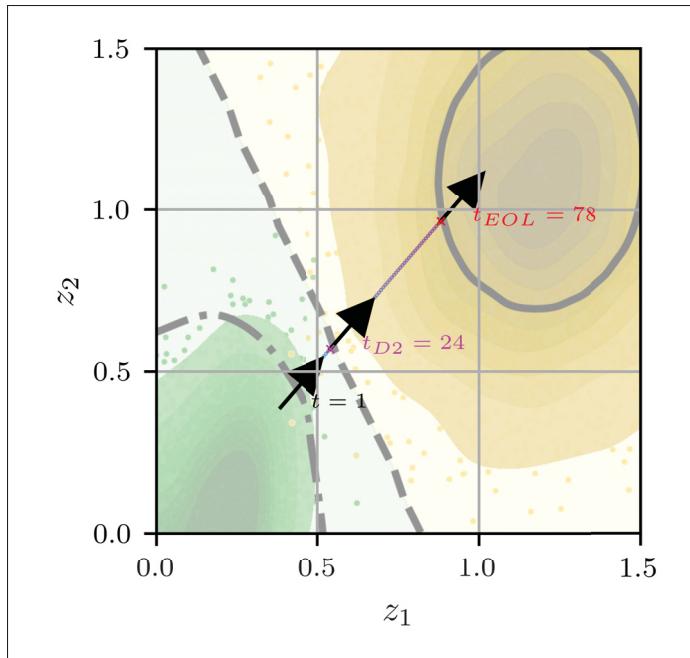


Figure 5.8 Linear degradation trajectory

the ground-truth-RUL. Moreover, the RUL dispersion decreases over time. Also, the RUL pdf close to the expected EOL is asymmetric, which is consistent with the fact that the RUL is nonnegative ( $\text{RUL} \geq 0$ ).

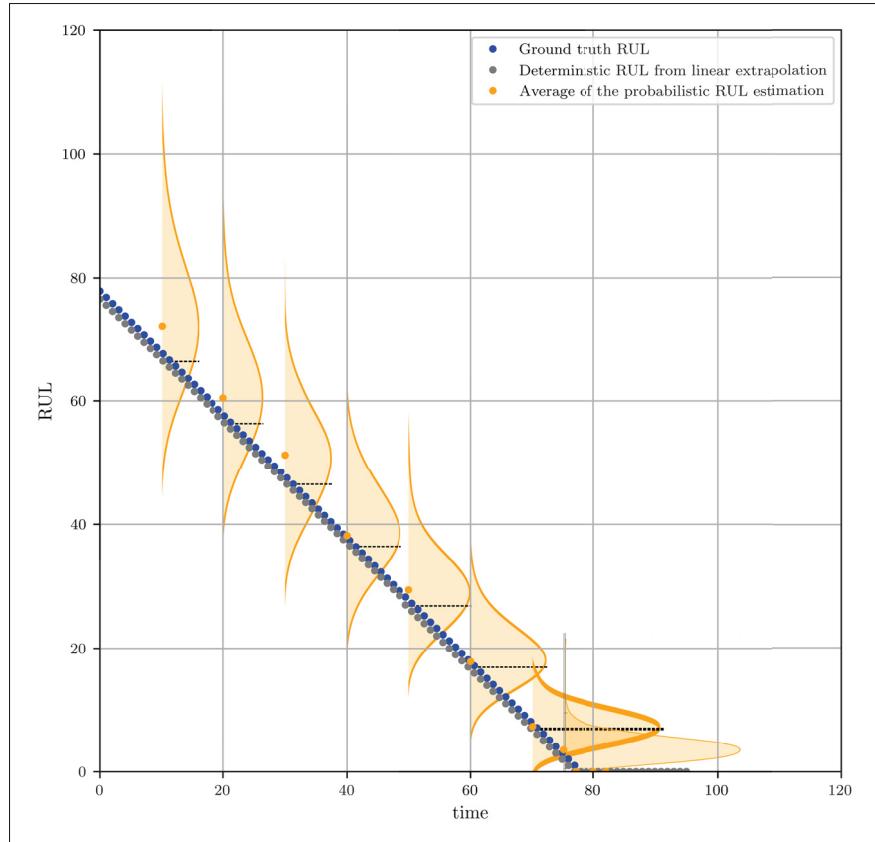


Figure 5.9 RUL estimation for the linear degradation trajectory

#### 5.4.3.2 A Curvilinear Trajectory

The synthetic trajectory depicted in Fig. 5.10 (See page 150) combines linear and harmonic functions and no random noise. This case aims at demonstrating the approach on a more realistic pattern.

Fig. 5.11 depicts the central estimation and the pdf for multiple time instants. The corresponding ground-truth RUL function is estimated from the  $t_{EOL} = 87$ , which is the instant when the trajectory intersects  $\Gamma_{EOL}$ .

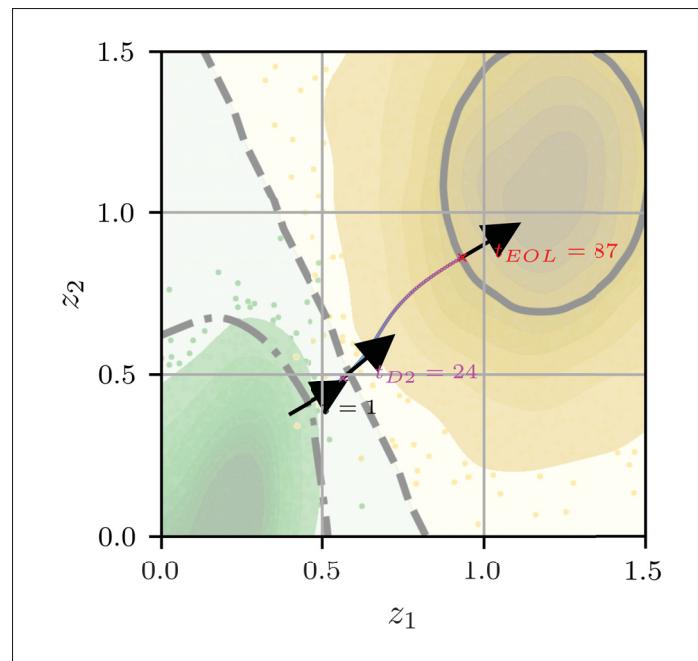


Figure 5.10 Curvilinear degradation trajectory

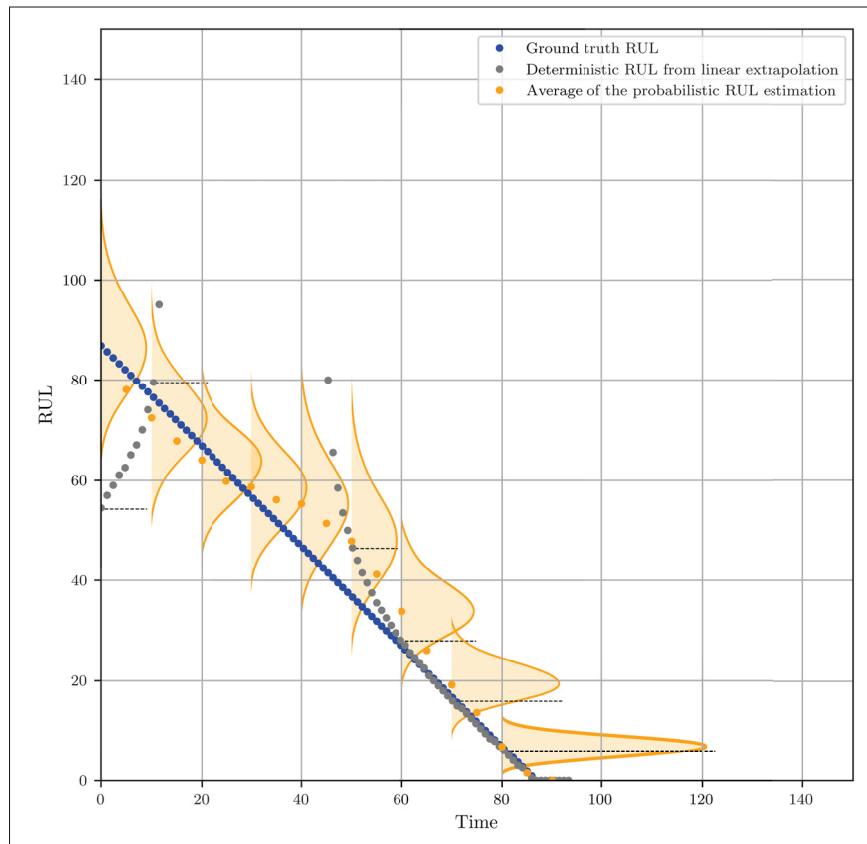


Figure 5.11 RUL estimation for the curvilinear trajectory

The deterministic RUL estimation diverges in period [10, 40] due to the linear extrapolation from points of the curvilinear trajectory not intersecting  $\Gamma_{EOL}$ . Nevertheless, the predicted RUL pdf gets increasingly accurate over time.

#### 5.4.4 Prognosis for a Degraded Wind Turbine Main Bearing

This section applies the proposed prognosis approach to a run-to-fail case study consisting of a WT whose main bearing degraded within four months. See Fig. 5.7(b). The latent space projection of the SCADA data points covering the interest interval is depicted in Fig. 5.12. The latent space projected points are highly dispersed. This is due to the randomness in the physical data itself, given the stochastic nature of measures such as the wind speed and temperature, as well as the complex and non-linear relations between variables.

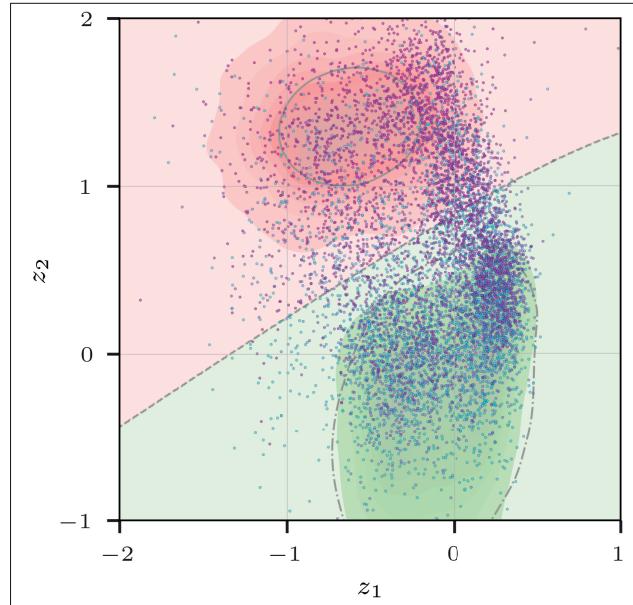


Figure 5.12 Latent space projection of SCADA data points

To describe the highly dispersed latent space projection as a trajectory in the latent space, the regularization of the data is required. We propose two levels of regularization. First, a moving

average is used to obtain a trajectory description from the set of points. The moving average is defined by two parameters : the time window  $\Delta_W$  and the time lag  $\Delta_L$ .

Nevertheless, the resulting trajectories are not smooth and, therefore, their time derivatives are not well defined. Thus, to ensure the trajectory is smooth as required by the proposed approach, one can use the WPR with weights adjusted to enforce the approximation around chosen periods. In this paper, the weights are defined to penalize the error closer to the extremities. The WPR of order 5 use polynomial interpolation with a weighting function  $w_i = 1 - 0.25 \sin(\pi x_i)$ , where  $x_i \in [0, 1]$  depicted in Fig. 5.13.

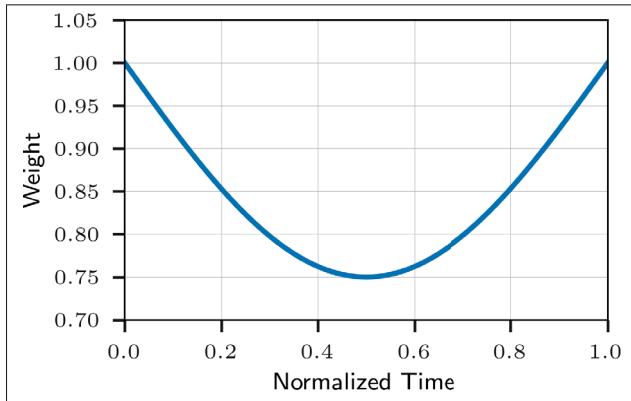


Figure 5.13 Weight function for the WPR

Fig. 5.14(a)—5.14(c) depict the MA-regularized trajectories for different settings  $\{\Delta_W, \Delta_L\}$  and the respective 5<sup>th</sup>-order WPR approximations. The WPR allows for obtaining smooth trajectories from the regularized yet highly dispersed trajectories. The trajectories obtained from the different combinations of regularization and WPR are visually similar, except to the extremities.

To evaluate the effect of the MA regularization and the WPR, Table 5.4 compares, for different values of  $\Delta_W$ , the following metrics : (1) coefficient of determination  $R^2$  , (2) Root Mean Squared Error (RMSE), (3) instant  $t_{D2}$  and (4) EOL instant  $t_{EOL}$ .

Table 5.4 shows that the regularization parameter  $\Delta_W$  enhances the performances of the WPR performed from the regularized data. This result suggests the model becomes more accurate and

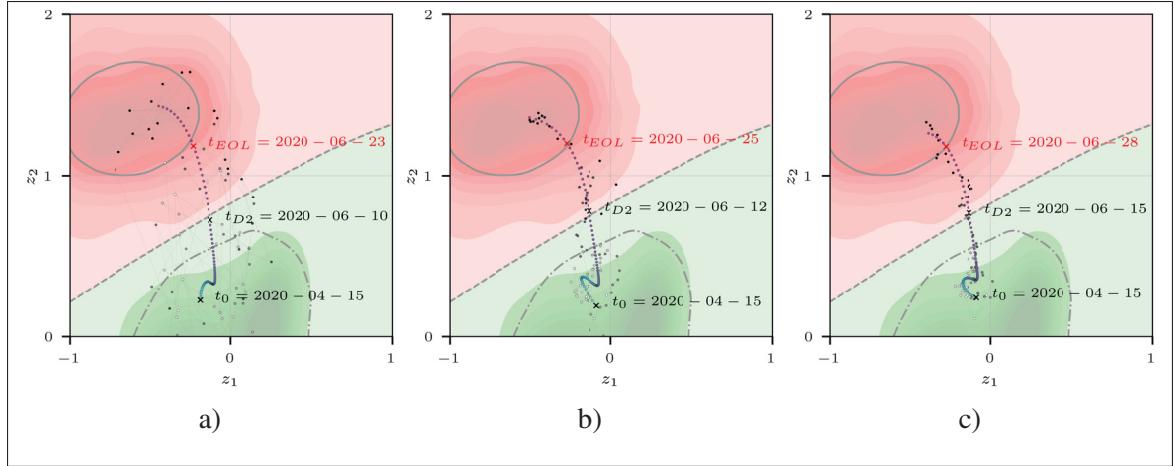


Figure 5.14 MA regularization and WPR with  $\Delta_L = 1\text{day}$  and  
(a)  $\Delta_W = 1\text{day}$ , (b)  $\Delta_W = 7\text{days}$ , (c)  $\Delta_W = 15\text{days}$

Tableau 5.4 Influence of the regularization parameter  $\Delta_W$

$\Delta_W$ (days)	$R^2$	RMSE [uz]	$t_{D2}$ (date)	$t_{EOL}$ (date)
1	-5.59	0.21	2020-06-10	2020-06-23
3	-1.04	0.14	2020-06-10	2020-06-23
7	0.48	0.07	2020-06-12	2020-06-25
15	0.78	0.035	2020-06-15	2020-06-28
18	0.82	0.027	2020-06-16	2020-06-29

stable with a larger moving average window. On the other hand, the bigger  $\Delta_W$ , the later are the instants  $t_{D2}$  and  $t_{EOL}$ . This means that the regularization implies a shift in the critical dates that could eventually delay responsive actions. Hence, the trajectory with the regularization parameters  $\Delta_W = 1\text{ day}$  and  $\Delta_L = 1\text{ day}$  was retained for estimating the RUL distribution.

Fig. 5.15 depicts the RUL pdf estimation over the WT lifetime after the early detection of the main bearing degradation.

Fig. 5.15(a) shows that the dispersion of the RUL estimation decreases over time, especially close to the EOL. This result aligns with observations for the synthetic trajectories. The estimation diverges within the interval [10days, 30days] because of the inflection of the trajectory within this period. Fig. 5.15(b) and Fig. 5.15(c) depict the RUL pdf at two instants close to the EOL.

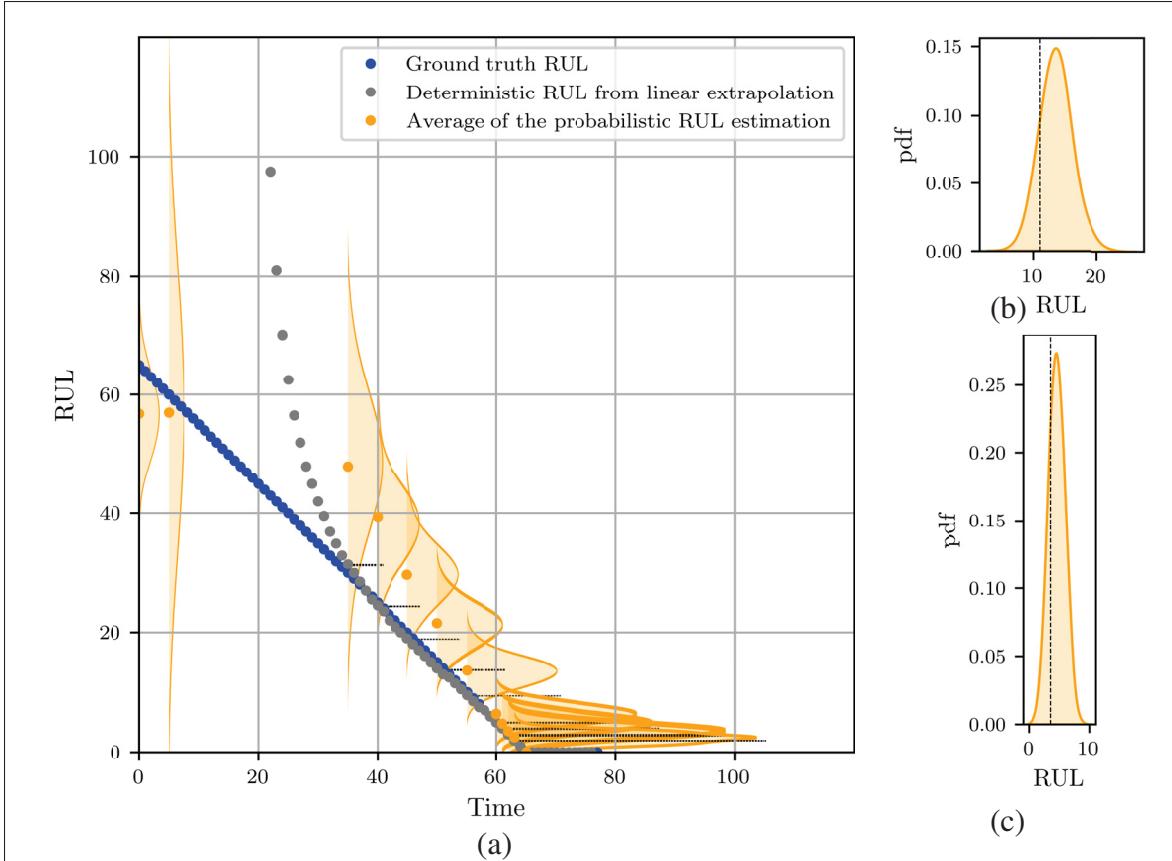


Figure 5.15 RUL pdf estimation for WT with degraded main bearing  
 (a) over time, (b) at  $t = 55$  days, and (c)  $t = 63$  days

Dashed black lines indicate the central RUL estimation. In particular, Fig. 5.15(c) reveals the asymmetric pdf, which is consistent with the condition  $\text{RUL} \geq 0$ .

## 5.5 Conclusion and Prospects

This paper introduced a new approach for estimating the RUL probability distribution from LVM latent space representations. The proposed approach relies on describing the system's latent space projection as a smooth trajectory.

Case studies from multiple application domains admit the latent space representation when an LVM is appropriately defined and trained. Under certain conditions, the latent space projection

of time-oriented datasets can be described as smooth trajectories. This paper introduced a new approach for estimating the RUL pdf based on the system's trajectory on the latent space.

The characterization of the EOL strongly influences the RUL estimation. This paper discussed the EOL criteria according to the application domain's criticality and the degradation mode under analysis.

The proposed approach was demonstrated for estimating the RUL for WTs given the measures from the SCADA system. First, we showed that the VAEC model allows for projecting the WT SCADA measures in a latent space representative of the WT health state. Indeed, different conditions project as disentangled clusters in the latent space. First, two synthetic trajectories demonstrated the rationale of the proposed approach. Then, the real-life case study of a degraded main bearing allowed for demonstrating the approach considering the steps to define a smooth trajectory from the projection of the SCADA data. The proposed approach allowed for obtaining RUL estimations consistent with the ground-truth RUL. Also, the dispersion of the RUL estimations decreases over time. The proposed approach does not impose any prior distribution, and the RUL estimations capture the asymmetric probability distribution close to the EOL.

Ongoing research includes the application of the proposed approach to other application domains and databases, as well as the performance assessment of the RUL estimator, including comparison with competing approaches.



## CHAPITRE 6

### SOMMAIRE ET CONTRIBUTIONS DES ARTICLES

Ce chapitre fournit un sommaire des articles scientifiques reproduits dans les chapitres 3, 4 et 5, en soulignant leurs contributions respectives. La figure 6.1 situe les trois articles dans le cadre du processus PHM basé sur la représentation latente des éoliennes. L'espace latent du VAEC a été utilisé pour définir des approches pour la détection, le diagnostic et le pronostic des éoliennes.

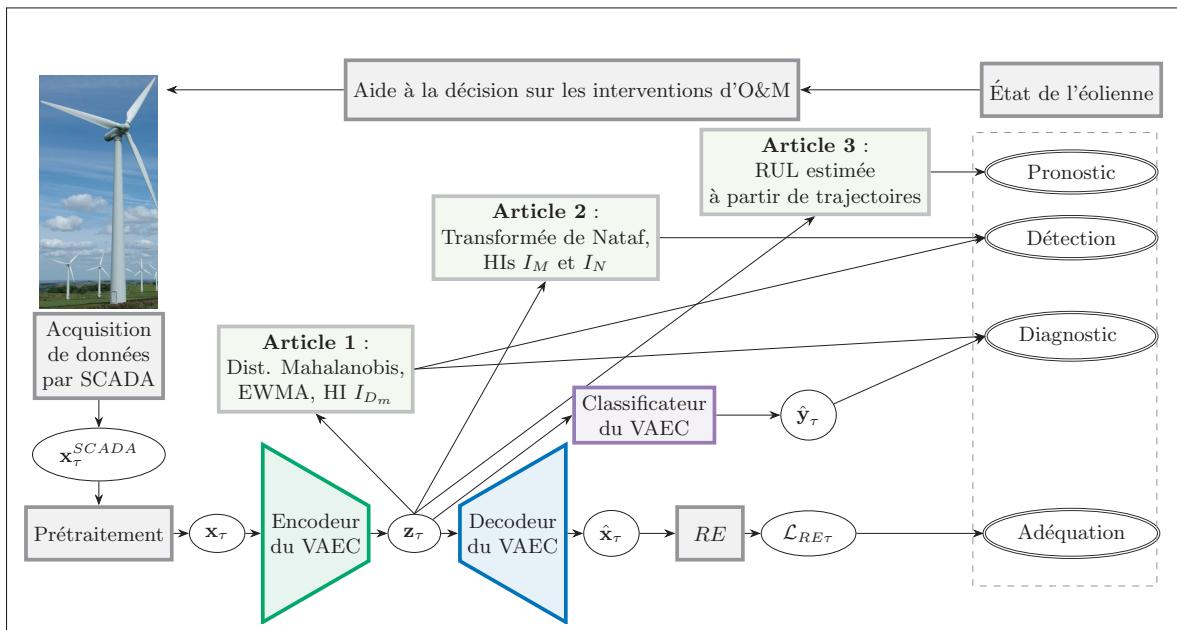


Figure 6.1 Vue d'ensemble de la production scientifique

Ce chapitre est structuré comme suit : la section 6.1 résume la portée et les hypothèses communes aux trois articles ; la section 6.2 établit une vue d'ensemble des modèles à variables latentes et discute l'usage de l'espace latent comme un outil d'analyse et de visualisation ; enfin, la section 6.3 présente en détail les principales contributions de chacun des articles.

#### 6.1 Portée et hypothèses de la recherche

Cette thèse a investigué et implémenté le processus d'analyse PHM pour les éoliennes décrites par les mesures physiques du système SCADA. La recherche a été motivée par le besoin industriel

pour modèles et méthodes pour appuyer la prise de décisions concernant l’O&M des éoliennes. Le but ultime du processus d’analyse PHM est de permettre la mise en place de stratégies optimales de maintenance telles que la maintenance prédictive. Par rapport aux stratégies de maintenance curative et systématique couramment utilisées, la maintenance prédictive est censée apporter des gains en fiabilité et disponibilité des actifs, ainsi que la réduction des coûts d’O&M.

La recherche s'est intéressé à des systèmes complexes décrits par un grand nombre de variables informant la condition du système. Des modèles d'IA à variables latentes ont permis de définir des approches interprétables pour la détection, le diagnostic et le pronostic des éoliennes.

Chaque article de cette thèse s'établit avec des hypothèses particulières. Les hypothèses communes aux trois publications sont listées ci-dessous :

- Les séries temporelles mesurées dans les systèmes d'intérêt définissent un espace physique à haute dimensionnalité. Les comportements anormaux ont des signatures sur les mesures physiques. Pour les éoliennes en particulier, la recherche s'est concentrée sur les éoliennes munies du système SCADA seulement (absence de données d'un système de surveillance de l'état de santé). L'espace physique des mesures SCADA est complexe à analyser à cause (i) du nombre de variables (ii) des relations non linéaires entre elles et (iii) de la nature stochastique des données d'entrée.
- Les systèmes complexes opèrent idéalement selon des conditions nominales. Le système est alors dans un état de santé sain. L'usure et les chargements répétés pendant l'opération peuvent amener à la transition vers une condition anormale d'opération. Lorsque la condition anormale d'un composant ou système est irréversible et cumulative, elle caractérise une dégradation. Un mode de dégradation peut évoluer jusqu'à la défaillance.
- Les travaux proposés sont basés sur l'hypothèse fondamentale qu'un seul état est observé à la fois. Cela revient à dire que les jeux de données correspondant aux différentes classes d'opération sont des ensembles disjoints. En réalité, il est possible que deux composants critiques se dégradent simultanément. Dans ce cas, pour des fins de l'implémentation, un de ces modes de dégradation est considéré comme prédominant.

- Les variables latentes des modèles dérivés du VAE n'ont pas de signification physique. En effet, les variables latentes sont des variables indirectes qui ne pourraient pas être mesurées par des capteurs. Les variables latentes concentrent les informations et relations le plus importantes pour caractériser le système. Dans chaque implémentation, le modèle a été défini avec un espace latent à deux dimensions (2D). Ce choix favorise l'usage de l'espace latent comme un outil de visualisation et s'est avéré approprié et commode pour représenter les systèmes analysés, notamment les éoliennes. Certes, l'espace latent peut être défini avec de plus hautes dimensions (3D ou plus).
- Les seuils de détection pour le diagnostic et pour le pronostic ont été définis à partir de cas d'étude de dégradation. L'accès à de tels cas est important pour bien caractériser les seuils et les critères pour la définition de préalarmes, alarmes, fin de vie opérationnelle, etc.
- L'espace latent fournit un outil de visualisation permettant d'interpréter les résultats des modèles d'IA. Cette explicabilité des résultats se fait notamment à partir de cas d'étude de dégradation de composants critiques.

Certaines hypothèses peuvent être relaxées, voire levées, pour permettre d'implémenter la méthodologie et la modélisation à d'autres systèmes ou domaines d'application. Les approches proposées peuvent en effet être généralisées à d'autres systèmes complexes à condition qu'ils soient décrits par des données appropriées. La possibilité de généralisation à d'autres systèmes a d'ailleurs été démontrée avec la base de données C-MAPPS décrivant l'opération de moteurs d'avions commerciaux dans le chapitre 4. Le chapitre Recommandations fournit des recommandations détaillées pour des recherches futures, y compris des recommandations pouvant amener à la généralisation des résultats à d'autres systèmes.

## 6.2 L'espace latent du VAEC comme un outil d'analyse et de visualisation

Une contribution majeure de cette thèse a été de démontrer que l'espace latent du VAEC permet de compresser et de projeter les données SCADA provenant d'éoliennes en opération. Nous avons montré que l'espace latent ainsi défini est représentatif de l'état physique des éoliennes.

Les trois articles de cette thèse ont démontré la pertinence d'utiliser l'espace latent du VAEC pour analyser et visualiser l'évolution de l'état de santé des éoliennes.

Ici, il convient de reprendre les arguments qui ont motivé l'adoption des modèles à variables latentes basés sur le VAE. Premièrement, le VAE possède une performance éprouvée pour l'analyse des systèmes décrits par un grand nombre de variables. Deuxièmement, ce modèle admet des adaptations pour des usages spécifiques. Le VAEC en est un exemple. Troisièmement, l'espace latent de dimension deux ou trois constitue un outil de visualisation qui confère de l'interprétabilité aux modèles à variables latentes.

Les variations semi-supervisées et supervisées du VAE améliorent les performances par la prise en compte de l'information sur les classes des données (Kingma *et al.*, 2014). Dans le modèle VAEC, le module de classification utilise l'espace latent comme entrée pour faire la classification de l'état du système. Le module de classification a une influence sur la distribution de l'espace latent. Le chapitre 3 a montré que, lorsque l'espace latent du VAE classique présente des clusters superposés, le VAEC peut être défini et entraîné pour aboutir à une représentation latente avec des clusters bien séparés.

Le premier article (chapitre 3) a utilisé une métrique basée sur la distance de Mahalanobis pour détecter l'éloignement des points projetés sur l'espace latent par rapport au cluster correspondant à l'état sain d'opération. Cette proposition nécessite que le cluster sain dans l'espace latent suive approximativement la distribution gaussienne. Une étape raffinée de définition du modèle VAEC est requise pour assurer cette distribution spécifique de l'espace latent. Le deuxième article (chapitre 4) a introduit la transformée de Nataf pour contourner l'étape coûteuse de la définition du VAEC. La projection dans l'espace standard de Nataf a un effet de régularisation de l'espace latent, ce qui relaxe les hyperparamètres admissibles pour la définition du modèle VAEC. Le deuxième article a donc permis de s'affranchir des contraintes imposées dans l'article 1 sur la distribution de l'espace latent. En outre, l'effet de cette transformée est de se concentrer sur la condition saine tout en y associant la distribution normale multivariée. Deux HI complémentaires ont été définis à partir de l'espace standard de Nataf. Ces HI ont permis d'anticiper la détection

par rapport à l'approche utilisant la distance de Mahalanobis. Le troisième article (chapitre 5) a introduit un modèle de pronostic pour estimer la RUL à partir de trajectoires dans l'espace latent. Les trajectoires décrivent l'évolution de la projection des données sur l'espace latent.

Les publications ont démontré l'usage de l'espace latent comme un outil de visualisation. Cela contraste avec des modèles de type boîte noire dont les résultats ne peuvent pas être interprétés objectivement. C'est un atout important dans un cadre technique ou industriel puisqu'il renforce la confiance des utilisateurs sur les résultats.

Pour conclure, nous tenons à souligner que la mise au point du modèle VAEC pour l'analyse PHM des éoliennes a reçu des contributions précieuses des chercheurs et analystes de chez Power Factors et de l'IREQ. La base de données décrivant les conditions critiques d'opération des éoliennes a été bâtie avec l'appui des experts de chez Power Factors. La définition de l'architecture et des hyperparamètres du modèle VAEC a bénéficié des contributions de l'IREQ, notamment de l'expertise du chercheur Ryad Zemouri, Ph. D. (Zemouri *et al.*, 2019, 2022, 2023; Proteau *et al.*, 2020).

### **6.3 Contributions des articles par question de recherche**

Cette section décrit les contributions de chaque article spécifiques à chacune des questions de recherche. Pour rappel, les questions de recherche couvrent les étapes du processus d'analyse PHM : QR1 Acquisition et traitement des données ; QR2 Détection ; QR3 Diagnostic ; QR4 Pronostic ; QR5 Interprétabilité. Les tableaux 6.1, 6.2 et 6.3 listent les principales contributions des articles 1, 2 et 3, respectivement.

Tableau 6.1 Contributions de l'article 1

QR	Contributions
QR1	<ul style="list-style-type: none"> <li>L'article a introduit une méthodologie pour bâtir une base de données labélisée comprenant cinq états : sain, surchauffe du roulement principal, surchauffe du générateur, surchauffe de la boîte de vitesses et givre sur les pales. L'étiquetage utilise des données SCADA, des fichiers <i>log</i> SCADA et des rapports d'O&amp;M.</li> <li>Des données provenant de plusieurs éoliennes ont été rassemblées pour produire une base de données représentative des conditions d'opération d'un modèle d'éolienne avec puissance installée d'ordre de 2MW.</li> <li>Une technique d'augmentation de données basée sur le modèle VAE a été utilisée pour aboutir à une base de données balancée.</li> </ul>
QR2	<ul style="list-style-type: none"> <li>L'indicateur de santé <math>I_{Dm}</math> a été introduit à partir de la distance de Mahalanobis entre des points projetés dans l'espace latent et le cluster sain.</li> <li>La charte de contrôle EWMA a été utilisée pour identifier les tendances de changement de la série temporelle de <math>I_{Dm}</math>.</li> <li>L'indicateur <math>I_{Dm}</math> a été démontré sur des cas d'étude réels. L'approche de détection a permis de détecter la surchauffe du roulement principal 11 jours avant l'alarme du système SCADA.</li> </ul>
QR3	<ul style="list-style-type: none"> <li>Le modèle VAEC comprend un DNN classificateur qui prend l'espace latent comme entrée. Sa dernière couche est configurée avec la fonction d'activation Softmax. La sortie du classificateur est un vecteur qui indique les probabilités d'appartenance aux différents états.</li> <li>L'entraînement du modèle VAEC a permis d'obtenir un classificateur avec une matrice de confusion indiquant plus de 98% de précision pour chacune des classes.</li> </ul>
QR5	<ul style="list-style-type: none"> <li>L'article a introduit un outil de visualisation basé sur l'espace latent 2D pour une interprétation intuitive des résultats du modèle.</li> <li>L'article montre que l'espace latent permet de représenter l'évolution de la condition des éoliennes comme des trajectoires. Des marqueurs colorés et de lignes ont été utilisés pour illustrer le passage du temps et la progression de l'état de santé.</li> <li>Il a été démontré que l'espace latent fournit une visualisation pour le diagnostic, avec des points projetés sur les clusters correspondants aux états de santé diagnostiqués.</li> </ul>

Tableau 6.2 Contributions de l'article 2

QR	Contribution
QR1	<ul style="list-style-type: none"> <li>L'article a démontré l'approche proposée sur deux bases de données, la base de données C-MAPSS et une base de données SCADA de l'opération des éoliennes.</li> </ul>
QR2	<ul style="list-style-type: none"> <li>L'article a proposé d'utiliser la transformée de Nataf pour projeter l'espace latent du VAEC dans l'espace standard de Nataf défini par rapport au cluster sain. Les propriétés de l'espace standard de Nataf ont permis la définition de deux HI innovants : <math>I_M</math> et <math>I_N</math>. Il a été montré que les deux HI sont complémentaires et permettent de détecter des modes de dégradation distincts. L'opérateur logique OU a été utilisé pour combiner les deux HI et les critères d'alarme respectifs.</li> <li>L'espace standard de Nataf se concentre sur la condition saine, ce qui permet de détecter des comportements anormaux plus tôt que les approches utilisant uniquement l'espace latent.</li> </ul>
QR5	<ul style="list-style-type: none"> <li>L'étude a démontré l'usage de l'espace standard de Nataf comme outil de visualisation.</li> </ul>

Tableau 6.3 Contributions de l'article 3

QR	Contributions
QR4	<ul style="list-style-type: none"> <li>L'article a introduit une approche innovante pour estimer la RUL à partir de l'espace latent. L'approche proposée est basée sur la description des modes de dégradation comme des trajectoires sur l'espace latent.</li> <li>L'expansion de Taylor a été utilisée pour déduire une approximation linéaire pour la trajectoire, ce qui a permis la proposition d'une estimation de la valeur centrale de la RUL. La méthode de Monte-Carlo a été utilisée pour estimer la pdf de la RUL.</li> <li>L'approche proposée a été démontrée avec trois études de cas <i>post mortem</i>, y compris celui de la dégradation du roulement principal d'une éolienne.</li> </ul>
QR5	<ul style="list-style-type: none"> <li>Cet article a montré comment représenter des modes de dégradation comme des trajectoires dans l'espace latent. Cette représentation exige la régularisation des données. La moyenne glissante est une option simple et efficace.</li> <li>La description de l'évolution des modes de dégradation sous forme de trajectoires s'avère utile pour le suivi visuel des tendances par les analystes et techniciens.</li> </ul>



## CONCLUSION GÉNÉRALE

Cette thèse a introduit des approches pour la détection, le diagnostic et le pronostic des éoliennes à partir des mesures SCADA et d'un modèle d'IA interprétable. Ces approches visent à appuyer des prises de décision sur l'O&M. Cette thèse s'ajoute donc aux efforts pour réduire les coûts d'O&M des éoliennes tout en augmentant leurs niveaux de fiabilité et de disponibilité. Comme indiqué dans l'Introduction, la mise en service de nouveaux parcs éoliens dépend de plusieurs facteurs, notamment de l'acceptabilité des populations locales, des choix politiques des gouvernements et de l'engagement des investisseurs. Ces acteurs sont influencés par la perception des éoliennes comme une solution appropriée pour faire face au changement climatique, d'où la pertinence des approches pour rendre les éoliennes encore plus fiables, disponibles et rentables.

Comme souligné dans le chapitre Revue de littérature, le PHM est un domaine en plein essor et l'implémentation des analyses PHM aux éoliennes est un sujet très actif. La majorité des analyses PHM pour les éoliennes exploitent les mesures SCADA 10-min. L'analyse des relations complexes entre ces mesures se fait le plus souvent avec des modèles d'IA. Cependant, le transfert technologique des approches basées sur l'IA est freiné par deux lacunes. La première lacune concerne les données utilisées. D'un côté, quelques travaux contournent le manque de données par l'usage de données fictives qui ne reflètent pas les particularités des données SCADA. De l'autre côté, plusieurs approches requièrent des données indisponibles pour la plupart des éoliennes. Des mesures telles que des signaux de vibration, de l'émission acoustique, de l'analyse de l'huile et des prises de vue ne sont guère disponibles pour les éoliennes en opération. La deuxième lacune concerne les modèles d'IA. Leur manque d'interprétabilité limite la confiance sur les résultats et, par conséquent, l'adhésion des opérateurs, analystes et techniciens des parcs éoliens.

Le chapitre 2, Objectifs et méthodologie, a présenté les objectifs spécifiques de notre recherche sous forme de question de recherche, se concentrant sur cinq étapes du processus d'analyse PHM : l'acquisition et le traitement des données (QR1), la détection (QR2), le diagnostic (QR3), le pronostic (QR4) et l'interprétabilité par les utilisateurs (QR5). La méthodologie adoptée inclut l'usage de données SCADA réelles provenant de parcs éoliens en opération. Le langage

Python a été utilisé pour implémenter le modèle VAEC. L'architecture et les hyperparamètres d'entraînement ont été définis et validés avec la base de données labellisée comprenant treize variables (*features*) et cinq états d'intérêt. Pour la validation et l'évaluation de la performance des approches proposées, nous avons utilisé des cas d'étude réels décrivant la dégradation de multiples composants.

Les articles scientifiques présentés aux chapitres 3, 4 et 5 ont apporté, à notre point de vue, des contributions majeures et potentiellement rayonnantes. Nous avons démontré la pertinence de l'utilisation de l'espace latent du modèle VAEC pour analyser et représenter visuellement les conditions du système éolien décrites par les mesures SCADA. Il convient de souligner que l'usage des données SCADA réelles provenant d'éoliennes en opération était un atout majeur pour notre recherche. Ceci a permis de tenir en compte des spécificités des mesures SCADA et de refléter la réalité du terrain. Finalement, le cadre d'analyse proposé permet de tenir compte de multiples classes de dégradation de façon simultanée et effective. Ce cadre d'analyse pourrait être adapté à d'autres domaines d'actifs.

Le chapitre 6, Sommaire et contributions des articles, indique que les articles scientifiques ont bien répondu aux questions de recherche fixées. Nous en soulignons le suivant :

- **QR1** Acquisition et traitement des données : Une approche a été proposée pour construire une base de données labellisée et balancée des conditions des éoliennes. Cette approche utilise des données SCADA et des rapports du système SCADA et des rapports d'O&M provenant de plusieurs éoliennes.
- **QR2** Détection : Des HI ont été définis à partir de l'espace latent pour la détection le plus tôt possible des conditions anormales de l'opération des éoliennes. Une contribution originale a été l'usage de l'espace standard de Nataf pour bien caractériser la condition saine, ce qui a permis d'introduire deux HI complémentaires permettant de détecter des anomalies plus tôt que les alarmes SCADA de référence.
- **QR3** Diagnostic : Le diagnostic est dérivé de deux éléments du modèle VAEC, soit l'espace latent et la sortie du module DNN de classification qui constitue le VAEC. Pour la surveillance

de l'état à un instant donné, les deux indications sont équivalentes. La position dans l'espace latent est une source d'information plus riche, car elle permet de suivre l'évolution de l'état au cours du temps selon la trajectoire des points projetés dans l'espace latent.

- **QR4** Pronostic : Un modèle de pronostic a été introduit à partir de la description de la projection dans l'espace latent comme une trajectoire. Une approche basée sur l'expansion de Taylor et la méthode de Monte-Carlo a été proposée pour estimer la cdf de la RUL pour les éoliennes.
- **QR5** Interprétabilité par les utilisateurs : L'espace latent du VAEC définit un outil de visualisation permettant d'expliquer les résultats des approches de détection, diagnostic et pronostic.

Outre les retombées scientifiques, les résultats de nos recherches apportent des contributions techniques et concurrentielles pour le partenaire industriel. Les propositions de la recherche donnent la base pour le développement d'une librairie informatique pouvant être intégrée aux outils actuellement utilisés pour le suivi de la performance et de l'état de santé des éoliennes. Le partenaire industriel, qui est un leader mondial avec des activités dans plusieurs pays, est en position privilégiée pour implémenter les approches proposées vu l'accès à une vaste base de données d'opération d'éoliennes, incluant plusieurs modèles d'éoliennes et des conditions d'opération diverses. Des discussions pour le transfert technologique ont fait partie des activités pour l'achèvement du doctorat.

Les méthodes retenues dans le cadre de notre recherche résultent d'un compromis entre l'adéquation vis-à-vis des objectifs posés et des ressources et du temps disponibles pour l'implémentation. Le chapitre 8 identifie les limites de cette thèse et fournit des recommandations pour la continuité des recherches et pour le transfert technologique.



## RECOMMANDATIONS

Ce dernier chapitre de la thèse présente nos recommandations pour la poursuite de la recherche et pour la mise en application des modèles proposés. La section 8.1 recense nos recommandations pour le prolongement de la recherche présentée dans cette thèse. La section 8.2 fournit des pistes d'investigation et d'approfondissement que nous croyons prometteuses dans le domaine de l'analyse PHM pour les éoliennes. La section 8.3 est une liste de recommandations pour le transfert technologique et le déploiement des méthodes et modèles issus de cette thèse.

### **8.1 Recommandations de recherche dans la continuité de cette thèse**

Nous présentons d'abord des pistes pour consolider et améliorer les approches proposées.

#### **8.1.1 Modèles non supervisés et semi-supervisés**

Le modèle VAEC utilisé est supervisé, ce qui demande la labellisation a priori de la base des données. La labellisation est une tâche chronophage et dépendante de la sensibilité des experts. Une piste d'amélioration importante est donc celle de l'usage de modèles à variables latentes semi-supervisés (Kingma *et al.*, 2014) ou non supervisés (Kingma & Welling, 2014).

Lorsque différentes conditions d'un système sont caractérisées par des descripteurs avec haut pouvoir informatif, l'espace latent du modèle VAE classique (non supervisé) présente des clusters séparés correspondant aux différentes conditions (Cheng & Chen, 2022). Les éoliennes sont des systèmes complexes et les mesures du système SCADA à elles seules n'informent que les comportements macroscopiques (Pandit & Wang, 2024). Par conséquent, le VAE n'est pas suffisant pour projeter les différentes conditions d'opération des éoliennes comme des clusters séparés dans l'espace latent. Le modèle supervisé VAEC a été exploité pour projeter les données SCADA provenant des éoliennes dans un espace latent à dimensionnalité réduite. Les gains de performance rapportés dans cette thèse ont été atteints en partie grâce à l'effort mis sur la définition des bases de données labellisées.

Zemouri *et al.* (2019) ont proposé une solution de raffinement itératif pour des modèles à variables latentes. Le schéma de leur approche est reproduit dans la figure 8.1. La zone où des clusters de classes distinctes se superposent est référée comme zone de conflit. Dans cette proposition, la supervision par un opérateur externe oriente le modèle vers l'amélioration de la classification. Pour réduire la zone de conflit de façon efficace, l'expert apporte des étiquettes à des données à proximité des zones de conflit. Les données ainsi étiquetées sont ensuite ajoutées à l'ensemble de données d'entraînement initial pour une nouvelle itération d'entraînement. C'est une solution intéressante qui permettrait de réduire le temps consacré à l'étape de préparation de la base de données pour l'entraînement du modèle.

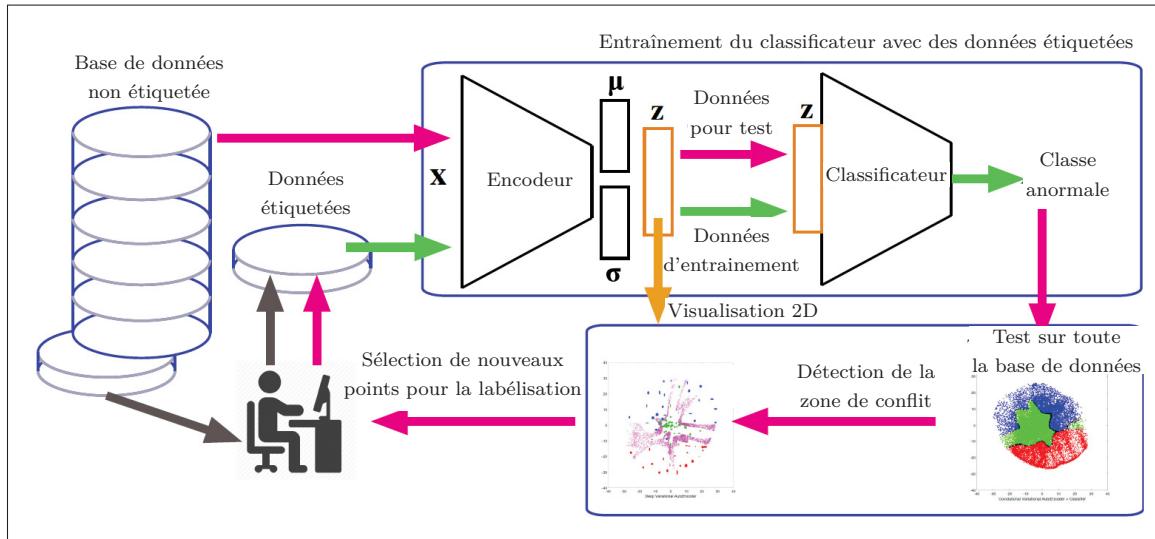


Figure 8.1 Approche de classification semi-supervisée avec le modèle de VAE convolutionnel et des ajustements itératifs de la zone de conflit

Adaptée de Zemouri *et al.* (2019, p. 5440)

### 8.1.2 Interprétabilité et explicabilité de l'intelligence artificielle

L'interprétabilité des modèles de l'IA est un sujet émergent et très actif (Cummins *et al.*, 2024). La nature « boîte noire » des modèles d'apprentissage machine est une limitation majeure à leur déploiement dans un contexte industriel. Deux techniques émergent dans la littérature de l'interprétabilité des modèles d'IA : (i) analyse de sensibilité à des perturbations sur les données et sur les paramètres, et (ii) outils de visualisation des modèles (Cummins *et al.*, 2024).

Cette thèse a proposé un outil de visualisation basé sur l'espace latent. Des cas d'études réelles ont été proposés pour montrer que l'outil de visualisation explique les résultats des approches pour la détection, le diagnostic et le pronostic.

La littérature compte peu d'indicateurs pour évaluer la performance des outils de visualisation (Astolfi, De Caro & Vaccaro, 2023). Une évaluation quantitative de l'outil de visualisation est parmi nos recommandations pour avancer la recherche proposée. Même si nous avons démontré l'utilité et la commodité de l'outil de visualisation avec des problèmes pratiques, l'apport sur le plan de la confiance et de l'adhésion aux résultats par les opérateurs, analystes et techniciens reste à valider et à évaluer. Aussi, l'hypothèse que l'outil de visualisation pourra contribuer à faciliter la communication et renforcer la confiance sur nos modèles devrait être vérifiée auprès d'un ensemble représentatif d'analystes et techniciens.

### **8.1.3 Détection de nouvelles classes de données et vérification de l'adéquation**

Le modèle VAE est défini pour reconstituer une approximation des données d'entrée. L'erreur de reconstruction  $\mathcal{L}_{RE}$  indique l'écart entre l'approximation produite par le modèle et les valeurs d'entrée. L'erreur  $\mathcal{L}_{RE}$  peut être utilisée pour la détection de classes d'opération qui ont été absentes de la base de données lors de la phase d'entraînement du modèle. En effet, l'erreur  $\mathcal{L}_{RE}$  reste petite pour des données que le modèle connaît (données dont les classes ont été utilisées pour entraîner le modèle). Au contraire, des données d'une nouvelle classe ne seront pas reconstruites correctement par le modèle, donc l'erreur  $\mathcal{L}_{RE}$  sera plus élevée. Ce principe est exploité dans plusieurs approches pour la détection d'anomalies (Park, Adosoglou & Pardalos, 2021; Nalisnick, Matsukawa, Teh, Gorur & Lakshminarayanan, 2018; Louizos & Welling, 2017; Hendrycks & Gimpel, 2016; Bengio, Courville & Vincent, 2013) et permet d'introduire un critère pour la vérification de l'adéquation des modèles à de nouvelles données (*suitability check*). Soit  $s_{RE}$  un seuil de l'erreur de reconstruction défini à partir de données historiques. La relation  $\mathcal{L}_{RE} \leq s_{RE}$  établit le critère pour l'adéquation de l'approche proposée aux données sous analyse. La figure 8.2 illustre ce critère.

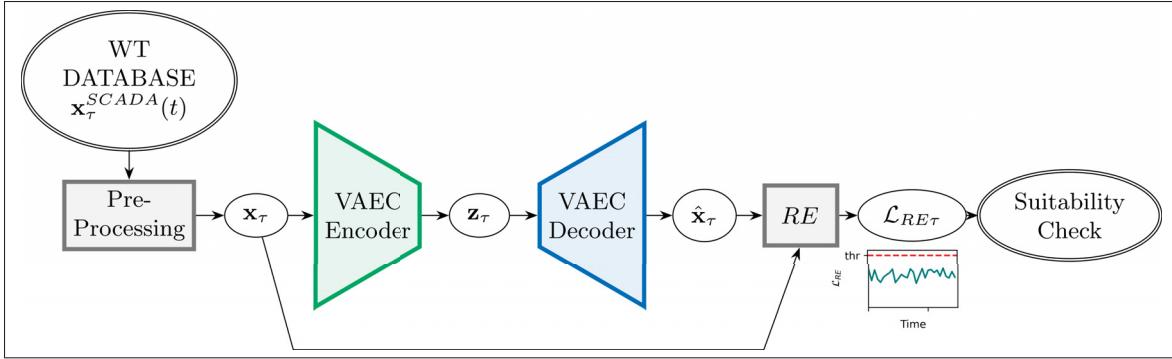


Figure 8.2 Vérification de l’adéquation à partir de l’erreur de reconstruction

En pratique, l’erreur de reconstruction est relativement élevée, par exemple au-delà de 15%, indique des données inconnues au modèle. Deux actions sont possibles dans un tel cas : (i) négliger les points n’appartenant pas à la base d’entraînement ou (ii) mettre à jour la base de données d’entraînement et réentraîner le modèle. Le choix entre ces deux options demande l’évaluation de la pertinence de l’éventuelle nouvelle classe de données pour l’analyse de l’état de santé du système d’intérêt.

#### 8.1.4 Espace latent à zones contraintes selon les conditions d’opération

Des entraînements indépendants du VAE engendrent des projections distinctes dans l’espace latent à cause des aléas dans la minimisation de la fonction coût et dans la définition du modèle VAE. Dans nos travaux précédents, nous avons fixé un entraînement spécifique qui a été ensuite utilisé pour les analyses PHM d’intérêt. Cette solution rend difficile la comparaison entre les modèles, même lorsque les modèles dérivent d’entraînements indépendants à partir de la même base de données.

Le chapitre 4 a présenté un outil pour la définition d’un espace latent standard à partir de la transformée de Nataf. Une autre piste de modélisation consisterait à introduire des contraintes dans la définition du modèle VAEC pour aboutir à un espace latent partitionné selon les différentes conditions d’opération, comme illustré dans la figure 8.3.

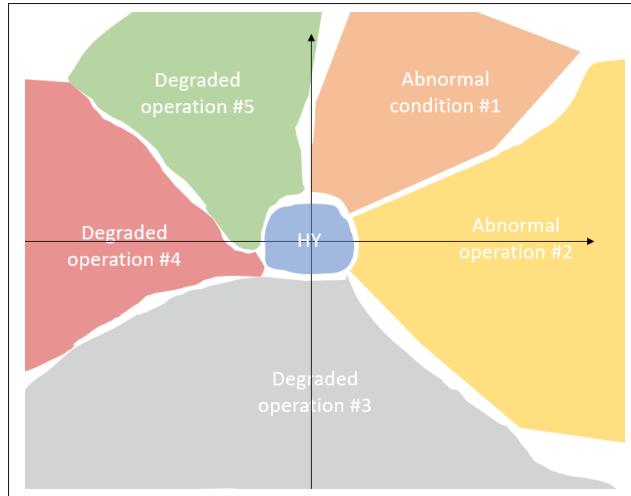


Figure 8.3 Partition de l'espace latent par conditions d'opération autour de la condition saine (HY)

Avoir la même projection pour plusieurs bases de données serait un avantage du point de vue industriel, car cela apporterait la simplicité de la présentation et la versatilité pour les différentes unités. Récemment, Ibrahim *et al.* (2024) ont implémenté ce principe à la surveillance de l'état de générateurs hydrauliques. Les auteurs ont montré que l'outil permet de comparer des unités de différents ordres de puissance active, ce qui a rempli le but d'avoir un outil applicable à une large gamme de systèmes. Pour la mise au point d'un tel modèle pour les éoliennes, nous préconisons la définition d'une fonction coût personnalisée selon les classes des données. En s'appuyant sur une approche supervisée, la fonction coût devrait inclure un terme qui pénalise des points d'une classe donnée tombant dehors de la section attribuée à cette condition. Cette fonction coût est référencée comme fonction de désirabilité dans (Ibrahim *et al.*, 2024).

### 8.1.5 Perfectionnement de la modélisation du pronostic

Le modèle de pronostic proposé a permis d'estimer la RUL pour plusieurs cas d'étude de dégradation des éoliennes. Cependant, des questions restent à adresser, notamment : comment peut-on améliorer le suivi temporel du passage d'une zone saine vers une zone dégradée ? Comment estimer le temps de transition et le taux de dégradation ? Suite à des réparations et à

des remises en état (*overhaul*), comment refaire l'apprentissage du modèle et des trajectoires ? Le doctorant et les coauteurs du troisième article de journal travaillaient pour adresser ces questions au moment de la rédaction de cette thèse.

## **8.2 Recommandations de recherche au-delà de la portée de cette thèse**

Les pistes de recherche listées dans cette session ont été identifiées au cours de nos travaux. Ces pistes dépassent la portée et les objectifs tels que définis au chapitre 2. Néanmoins, nous jugeons que ce sont des points d'intérêt majeurs pour le domaine de l'analyse PHM pour les éoliennes.

### **8.2.1 Apprentissage par transfert**

Une base de données avec indication des classes d'opération a été bâtie pour l'entraînement supervisé du modèle VAEC. Cette base de données a été construite avec des données provenant de plusieurs éoliennes puisque peu de cas de défaillance sont généralement observés pour chaque éolienne prise individuellement. Pour que la base de données soit représentative des éoliennes individuelles, il est important de sélectionner des éoliennes d'un même modèle opérant sous des conditions atmosphériques semblables. Cette démarche suppose que les éoliennes présentent des comportements équivalents entre elles pour chacune des conditions d'intérêt, y compris lors de l'opération normale. En pratique, cette hypothèse n'est valable que pour un parc éolien nouvellement commissionné, avec des unités quasiment identiques du point de vue structurel (pas de réparations majeures ou *overhaul*), et sur un relief relativement plan, ce qui implique des conditions de vent semblables (*wake effect* négligé).

L'hypothèse d'opération sous les mêmes conditions n'est pas vérifiée si : (i) plusieurs éoliennes du parc éolien ont subi des réparations majeures ou *overhaul*, ou (ii) le site du parc éolien est caractérisé par un relief irrégulier comme celui du parc éolien Gros Morne. Voir figure 8.4. Le relief irrégulier implique différentes conditions de vent (vitesse moyenne et niveau de turbulence) sur les différentes éoliennes de ce parc, comme illustré pour le parc éolien de Gros Morne dans la figure 8.5. Dans ces cas, différentes éoliennes opèrent sous conditions différentes. Il

serait donc pertinent de tenir compte des conditions spécifiques à chaque éolienne ou à des sous-ensembles d'éoliennes lors de l'étape d'apprentissage. Une piste pour pouvoir exploiter les approches proposées tout en tenant compte des particularités de chaque éolienne est la technique d'apprentissage par transfert (TL, *Transfer Learning*) (Liu, Cao & Zhang, 2021c). L'objectif du TL est de déployer un modèle formé sur les données d'un système donné vers un autre système qui est indépendant, mais similaire au système original. Plutôt que de reprendre l'entraînement du modèle à zéro avec un nouveau jeu de données, le TL cherche à adapter le modèle existant en utilisant les données du second système (Tan *et al.*, 2018). L'usage du TL pour analyser des parcs éoliens est un sujet en plein essor (Li, Jiang, Zhang & Shu, 2021; Al-Hajj, Assi, Neji, Ghandour & Al Barakeh, 2023; Yue, Jiang, Jin, He & Xie, 2024). Bonheme & Grzes (2023) analysent l'usage des modèles VAE dans une logique de TL.

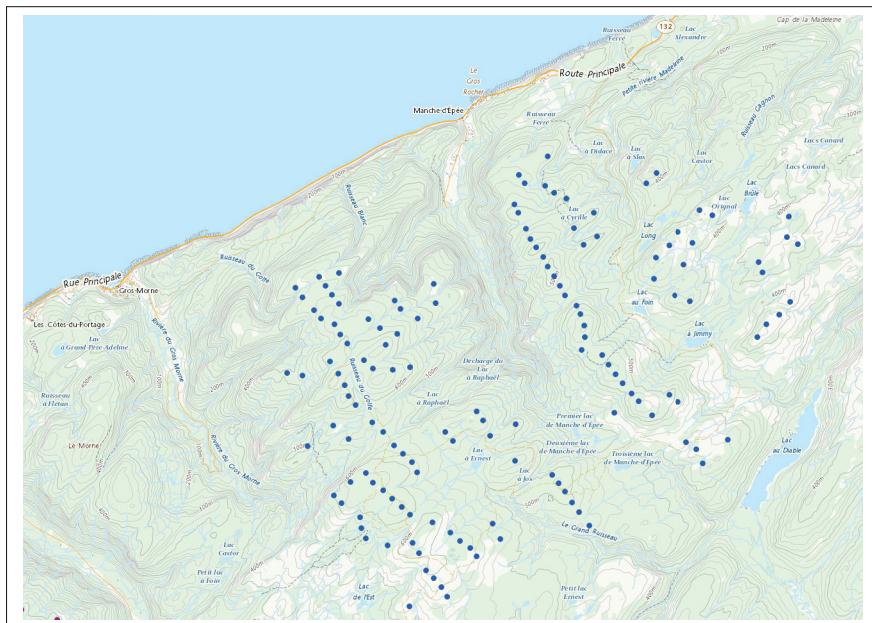


Figure 8.4 Plan topographique du Parc éolien de Gros Morne avec identification des positions des éoliennes  
Tirée de Ressources naturelles Canada (2024)

L'implémentation des approches de détection, diagnostic et pronostic proposées dans cette thèse passe par l'encodage des éoliennes avec le modèle VAEC. L'intérêt du TL serait donc d'entraîner un VAEC de base pour l'ensemble des éoliennes. Ensuite, en s'appuyant que le TL, de procéder

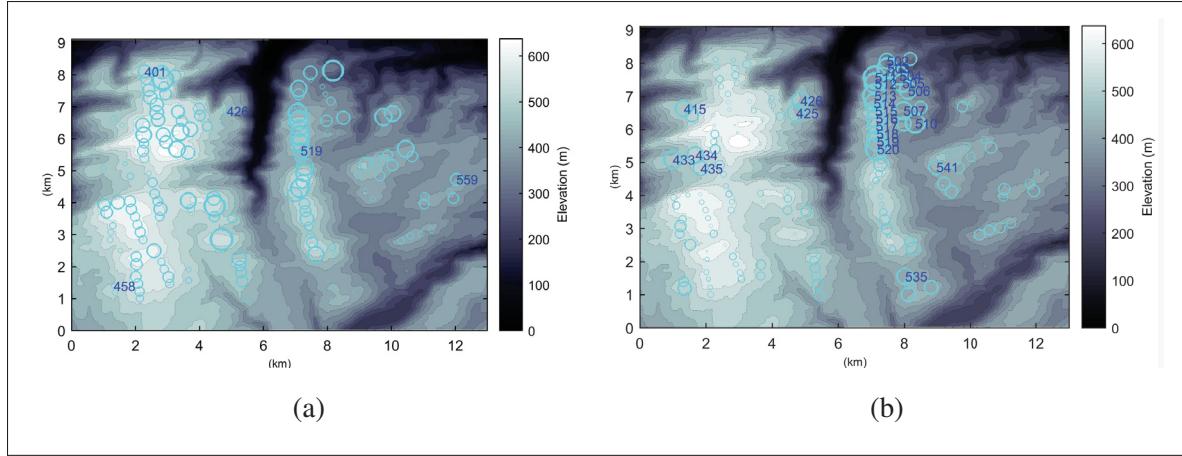


Figure 8.5 Indicateurs de dégradation pour le Parc éolien de Gros Morne : chaque marqueur correspond à une éolienne, et la taille de ces marqueurs indique

(a) la vitesse moyenne du vent et (b) la fréquence d'arrêts (*shutdown*)

Tirée du rapport de stage réalisé par le doctorant à l'ÉTS et à Power Factors en 2019

à un ajustement du modèle pour chaque éolienne tout en utilisant les mesures SCADA provenant de chaque éolienne prise individuellement.

### 8.2.2 Réseaux de neurones en graphes

Le modèle de réseaux de neurones en graphes (GNN, *Graph Neural Networks*) sont réputés de permettre la modélisation de systèmes complexes qui admettent la représentation sous forme de graphe (Liao, Bak-Jensen, Pillai, Wang & Wang, 2021). Plusieurs travaux dans la littérature récente rapportent des résultats encourageants pour l'analyse de l'état de santé des éoliennes avec les GNNs (Liu, Wang, Xie, Wu & Li, 2023; Feng, Liu & Jiang, 2023; Miele, Bonacina & Corsini, 2022). La pertinence du GNN vient du fait que la structuration des données en graphes tient compte de l'interdépendance entre descripteurs définissant l'espace physique de haute dimension. Cela a des avantages par rapport aux modèles DNN classiques construits à partir de la caractérisation des données dans un espace euclidien.

Les GNNs sont des modèles versatiles et se prêtent à des applications diverses (Liao *et al.*, 2021). Pour les éoliennes en particulier, les applications suivantes pourraient être envisagées :

prédition de la puissance générée, prédition de mesures spécifiques, détection d'anomalies, prise en compte des relations entre les éoliennes constituant un grand parc éolien, génération de données, etc. Dans (Liu *et al.*, 2023), un modèle GNN a été proposé pour modéliser l'état des éoliennes. Des résultats prometteurs ont été rapportés même si peu de mesures SCADA ont été utilisées. En effet, seulement des mesures de température ont été utilisées, dont 6 températures mesurées autour d'un même élément, le générateur. Or, des mesures telles que la vitesse du vent, la puissance active, la vitesse de rotation du rotor sont fondamentales pour la caractérisation effective de l'état d'opération des éoliennes. Nous recommandons donc d'implémenter le modèle GNN en utilisant davantage de données. Cela aura certainement un effet positif sur les modèles proposés.

L'accès à des données pertinent pour caractériser l'état des éoliennes reste un défi pour la modélisation avec le GNN. Pour pouvoir bien entraîner ce type de modèle, il faut que les données soient assez représentatives des dynamiques complexes entre les variables. La tendance actuelle c'est d'avoir des éoliennes plus grandes et en me s'accompagne de de la diversification des mesures physiques disponibles, ce qui ouvre la voie pour les modèles GNN (UpWind, 2011; McKenna, vd Leye & Fichtner, 2016). Ces modèles seront d'autant plus pertinents que les mesures disponibles se diversifient.

### **8.2.3 Modèles d'intelligence artificielle multimodaux**

Autre voie d'amélioration de la performance des modèles de suivi de condition et de pronostic est celle des modèles d'IA multimodaux. Il s'agit de modèles permettant la prise en compte de plusieurs types de données (Yang, Baraldi & Zio, 2021). Dans le cas des éoliennes, les modèles multimodaux seraient utiles pour tenir compte de données autres que les mesures SCADA 10 min, par exemple des données SCADA à haute fréquence d'acquisition (ordre du 1 Hz ou 1 kHz, voire plus), des données de vibration ou d'émission acoustique, des images, des rapports d'analyse d'huile, etc. Une solution gloutonne consisterait à transformer tous les types de données sous le même format. Par exemple, décrire les figures à partir des pixels ou associer les spectres à des séries temporelles. Cependant, ces transformations impliquent à la fois de la

perte d'information et l'alourdissement des coûts et temps pour le traitement numérique des données et des modèles.

Dans le scénario où de nouvelles mesures seront disponibles, il va falloir évaluer l'intégration de ces nouvelles données aux approches proposées. Ça pourrait permettre une meilleure caractérisation des interactions entre les différents symptômes des dégradations.

### **8.3 Recommandations pour le transfert technologique**

La recherche appliquée a été enrichie par des échanges hebdomadaires avec les partenaires industriels Power Factors et Hydro-Québec (IREQ). Ces discussions ont inspiré les recommandations pour le transfert technologique présentées dans cette section.

Le tableau 8.1 fournit un résumé des recommandations pour le transfert technologique.

Recommandation 1 : Automatisation du processus de labellisation. Présentement, une démarche semi-automatique est utilisée pour la labellisation de la base de données. L'approche intègre les considérations physiques et l'analyse des séries temporelles au cas par cas. Cette implémentation est chronophage et dépend de la sensibilité des experts. Une piste d'amélioration serait donc d'adopter des modèles pour la classification automatisée en amont. Des approches robustes pour la classification sont d'ailleurs parmi les outils développés par le partenaire Power Factors.

Recommandation 2 : Validation sur multiples parcs éoliens. Les modèles et approches proposés dans cette thèse sont généralisables à des éoliennes munies du système SCADA fournissant assez de mesures physiques. Il est important que les mesures suivantes soient disponibles : vitesse du vent, puissance active, rotation du rotor, et des mesures de température à plusieurs positions. Même que les données utilisées pour le développement et validation des modèles proviennent d'éoliennes avec une puissance installée individuelle proche de 2 MW, les propositions s'appliquent aussi à d'autres tailles d'éoliennes, ainsi qu'à divers manufacturiers et technologies. L'analyse sur d'autres parcs éoliens est recommandée notamment pour raffiner la définition des seuils pour la détection, les critères pour déclencher des alarmes et les paramètres pour les chartes de contrôle,

Tableau 8.1 Synthèse des recommandations pour le transfert technologique

Recommandation	Objectif	Agents	Métriques
(1) Automatisation du processus de labellisation	Réduction du temps et coût pour la labellisation des données, minimisation de la variabilité due aux opérateurs humains	Analystes de données, ingénieurs d'IA	Précision, efficacité et temps de la labellisation des données
(2) Validation sur multiples parcs éoliens	Évaluation de la généralisabilité et de la robustesse des approches, analyse des critères pour les seuils de détection, diagnostic et pronostic	Opérateurs, détendeurs des données SCADA, analystes de données	Performance de l'approche sur plusieurs parcs éoliens
(3) Protocoles pour la décision d'O&M	Définition de protocoles pour la planification des interventions de maintenance à partir des modèles de détection, diagnostic et pronostic	Opérateurs, manufacturiers, techniciens, fournisseurs de composants	Fréquence et temps d'arrêt pour la réparation de pannes, coûts de maintenance et d'implémentation
(4) Analyse quantitative des bénéfices	Évaluation chiffrée des économies potentielles pour justifier les investissements nécessaires	Analystes économiques, gestionnaires des parcs	Retour sur investissement, dépenses évitées
(5) Évaluation de l'outil de visualisation	Assurer la compréhension de l'outil de visualisation par les utilisateurs	Analystes de données, techniciens de maintenance	Satisfaction utilisateur, adhésion par les utilisateurs

si applicable. Idéalement, cette analyse devrait inclure plusieurs tailles d'éolienne, plusieurs constructeurs et des reliefs de parcs variés pour inclure différentes conditions d'opération.

Recommandation 3 : Protocoles pour la prise de décision à partir de la détection, du diagnostic et du pronostic. La planification des interventions d'inspection et réparation des éoliennes est une tâche complexe vu qu'elle comprend un grand nombre de variables et de contraintes (Nicod *et al.*, 2017; May *et al.*, 2015). Une stratégie e maintenance prédictive utilise le modèle de pronostic pour la planification des interventions. Pour cela, des protocoles pour l'aide à la

décision selon les résultats des modèles doivent être établis. Cette étape est souvent orientée par les considérations économiques.

Recommandation 4 : Analyse quantitative pour les bénéfices financiers et logistiques de la maintenance prédictive. La prémissse qui motive les modèles de pronostic est celle que la maintenance prédictive apporte des économies et gains en fiabilité et disponibilité par rapport aux stratégies de maintenance curative et préventive. Plusieurs travaux se penchent sur la comparaison économique des différentes stratégies de maintenance pour les éoliennes, en particulier (May *et al.*, 2015). Cette thèse n'inclut pas une étude chiffrée approfondie des gains économiques obtenus à partir des approches proposées. Cette analyse est parmi les recommandations pour le transfert technologique.

Recommandation 5 : Évaluation de l'outil de visualisation. L'outil de visualisation proposé vise à améliorer l'interprétabilité ou l'explicabilité des modèles d'IA. Nous recommandons d'évaluer l'outil auprès des usagers potentiels, surtout les analystes et les techniciens de maintenance. L'outil pourrait être adapté selon les conventions du partenaire industriel et des considérations sur le rendu graphique.

#### **8.4 Conclusion des recommandations**

Les nombreuses recommandations présentées dans ce dernier chapitre de la thèse donnent un aperçu de l'intense activité de recherche dans le domaine du PHM appliqué aux éoliennes. Les efforts pour avancer les questions ouvertes présentées dans ce chapitre motivent à la fois dans les laboratoires académiques et industriels. Le développement de solutions dans ce domaine est parmi les missions de l'entente CRSNG-Alliance qui regroupe l'ÉTS, Power Factors et l'IREQ. Les retombés de ce domaine de recherche dépassent les laboratoires académiques et l'industrie. Ce sont en effet des avancées pour un secteur d'énergie plus fiable, efficace et durable.

## ANNEXE I

### ARTICLES DE CONFÉRENCE, ARTICLES DE VULGARISATION SCIENTIFIQUE ET PRÉSENTATIONS ORALES

#### 1. Articles de conférence

##### 1.1 Conférence PHM 2022 à Londres

La figure I-1 reproduit la première page de l'article présenté dans la conférence PHM 2022. Le doctorant a fait une présentation orale à cette conférence. À la date de rédaction de cette thèse, cet article de conférence a été cité 4 fois (autocitations exclues). L'article (Oliveira-Filho *et al.*, 2022) est disponible à l'adresse DOI : <https://doi.org/10.1109/PHM2022-London52454.2022.00055>

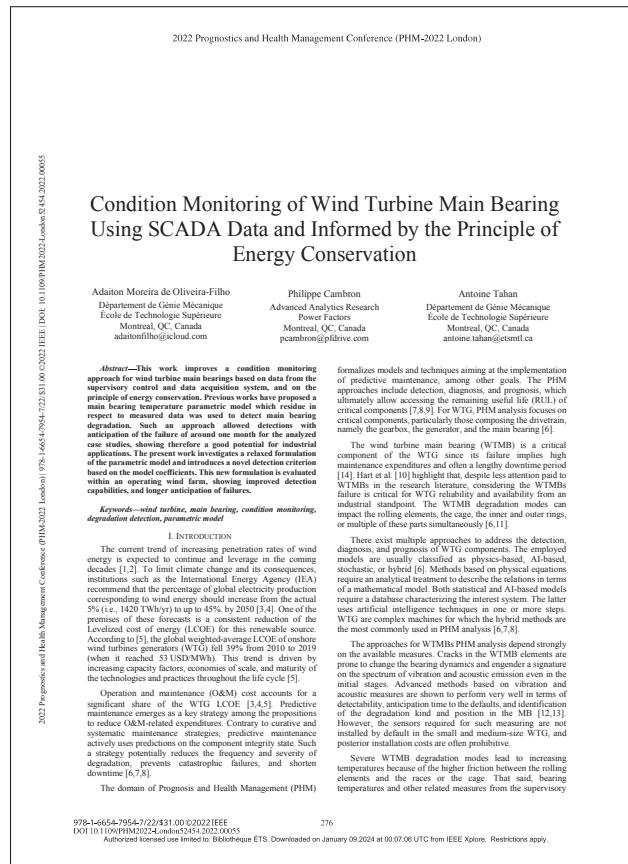


Figure-A I-1 Article présenté à la Conférence PHM 2022

## 1.2 Conférence PHM 2024 à Stockholm

La figure I-2 reproduit la première page de l'article soumis et accepté pour la conférence PHM 2024 qui aura lieu à Stockholm en mai 2024. <http://www.phmice.org/index.html>

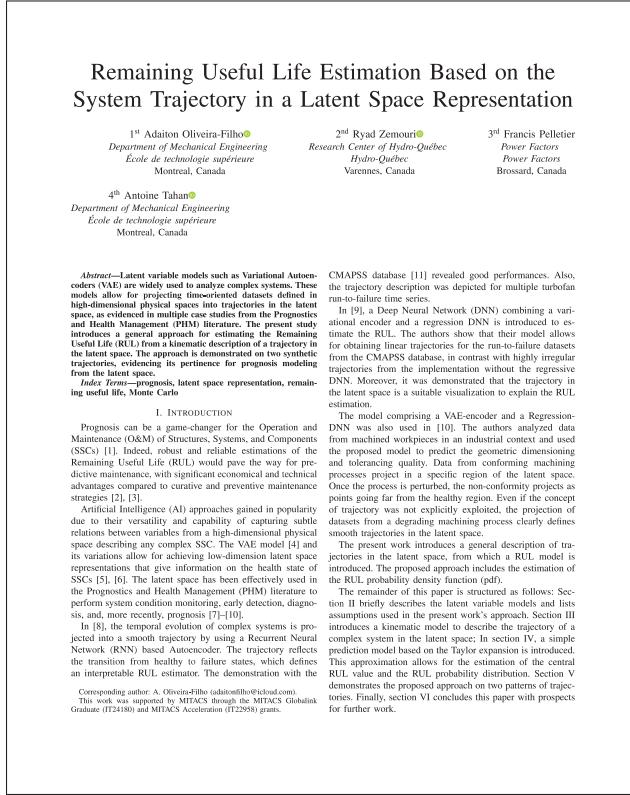


Figure-A I-2 Article acceptée à la Conférence PHM 2024 Stockholm

## 2. Présentations orales et activités de vulgarisation de la recherche

### 2.1 Forum international sur l'innovation 5.0

Le doctorant a présenté une affiche de vulgarisation scientifique au Forum international sur l'innovation 5.0 tenu le 9 novembre 2022 au Palais des Congrès de Montréal. L'affiche reproduite dans la figure I-3 a reçu le prix de meilleure affiche de vulgarisation scientifique.

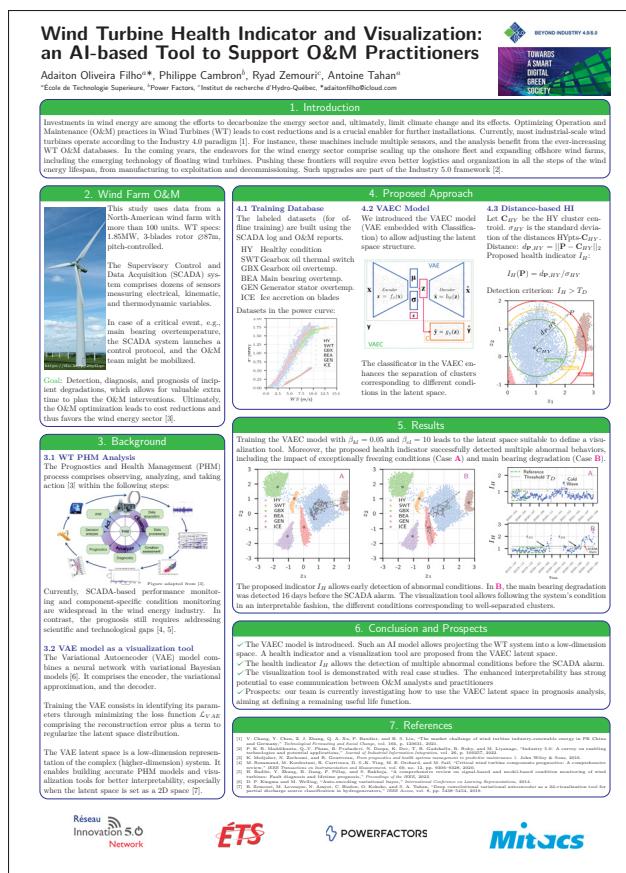
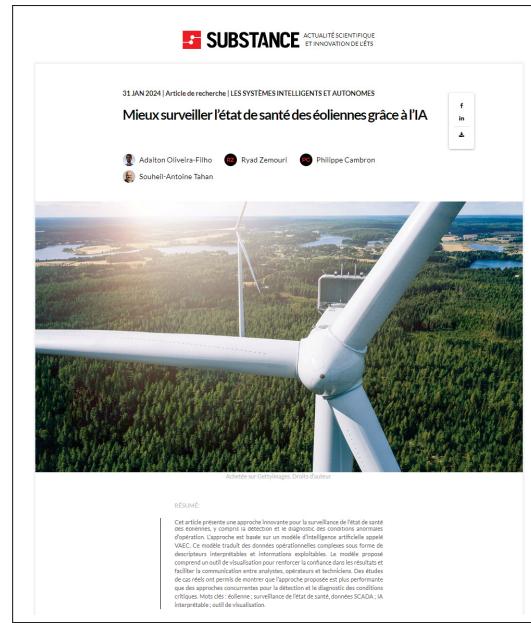


Figure-A I-3 Poster présenté au Forum international sur l'innovation 5.0

## 2.2 Article publié dans le journal Substance ÉTS

Notre article a été sélectionné dans le concours de la revue Substance ETS Édition 2023. L'article (Oliveira-Filho *et al.*, 2023), intitulé « Early Detection and Diagnosis of Wind Turbine Abnormal Conditions Using an Interpretable Supervised Variational Autoencoder Model », a été vulgarisé sous le titre « Mieux surveiller l'état de santé des éoliennes grâce à l'intelligence artificielle » (ou « *Building Trust in Wind Turbines with AI-Based Condition Monitoring* » pour la version en anglais). Cet article est disponible sur <https://substance.etsmtl.ca/mieux-surveiller-etat-sante-eoliennes-grace-ia>.



**Figure-A I-4** Première page de l’article de vulgarisation scientifique publié chez Substance ÉTS

### 2.3 Concours étudiant au Colloque 2024 de l’AQPER

Le doctorant a été sélectionné pour la finale du concours étudiant du Colloque 2024 de l’Association québécoise de la production d’énergie renouvelable (AQPER). Huit étudiants ont présenté leurs recherches dans le cadre du Colloque qui a eu lieu au Château Frontenac, à Québec, du 19 au 21 février 2024. L’événement a accueilli des acteurs majeurs de l’industrie des énergies renouvelables du Québec <https://colloque.aqper.com/fr/colloque2024-aqper>.

## BIBLIOGRAPHIE

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., Isard, M. et al. (2016). {TensorFlow} : a system for {Large-Scale} machine learning. *12th USENIX symposium on operating systems design and implementation (OSDI 16)*, pp. 265–283.
- Abid, K., Mouchaweh, M. S. & Cornez, L. (2018). Fault prognostics for the predictive maintenance of wind turbines : state of the art. *Joint european conference on machine learning and knowledge discovery in databases*, pp. 113–125.
- Al-Hajj, R., Assi, A., Neji, B., Ghandour, R. & Al Barakeh, Z. (2023). Transfer Learning for Renewable Energy Systems : A Survey. *Sustainability*, 15(11), 9131.
- Arias Chao, M., Kulkarni, C., Goebel, K. & Fink, O. (2021). Aircraft engine run-to-failure dataset under real flight conditions for prognostics and diagnostics. *Data*, 6(1), 5.
- Assemblée Nationale du Québec. [Présenté par M. Pierre Fitzgibbon, Ministre de l'Économie, de l'Innovation et de l'Énergie. Éditeur officiel du Québec, 2024]. (2024). Projet de loi n° 69 : Loi assurant la gouvernance responsable des ressources énergétiques et modifiant diverses dispositions législatives. Repéré à <https://www.assnat.qc.ca/fr/travaux-parlementaires/projets-loi/projet-loi-69-43-1.html>.
- Astolfi, D., Castellani, F., Lombardi, A. & Terzi, L. (2021). Multivariate SCADA data analysis methods for real-world wind turbine power curve monitoring. *Energies*, 14(4), 1105.
- Astolfi, D., De Caro, F. & Vaccaro, A. (2023). Condition Monitoring of Wind Turbine Systems by Explainable Artificial Intelligence Techniques. *Sensors*, 23(12), 5376.
- Atamuradov, V., Medjaher, K., Dersin, P., Lamoureux, B. & Zerhouni, N. (2017). Prognostics and health management for maintenance practitioners-Review, implementation and tools evaluation. *International Journal of Prognostics and Health Management*, 8(3), 1–31.
- Azimi, M., Eslamlou, A. D. & Pekcan, G. (2020). Data-driven structural health monitoring and damage detection through deep learning : State-of-the-art review. *Sensors*, 20(10), 2778.
- Badihi, H., Zhang, Y., Jiang, B., Pillay, P. & Rakheja, S. (2022). A comprehensive review on signal-based and model-based condition monitoring of wind turbines : Fault diagnosis and lifetime prognosis. *Proceedings of the IEEE*, 110(6), 754–806.

- Balshaw, R., Heyns, P. S., Wilke, D. N. & Schmidt, S. (2022). Importance of temporal preserving latent analysis for latent variable models in fault diagnostics of rotating machinery. *Mechanical Systems and Signal Processing*, 168, 108663. doi : <https://doi.org/10.1016/j.ymssp.2021.108663>.
- Balshaw, R., Heyns, P. S., Wilke, D. N. & Schmidt, S. (2023). Latent indicators for temporal-preserving latent variable models in vibration-based condition monitoring under non-stationary conditions. *Mechanical Systems and Signal Processing*, 199, 110446. doi : <https://doi.org/10.1016/j.ymssp.2023.110446>.
- Banko, L., Maffettone, P. M., Naujoks, D., Olds, D. & Ludwig, A. (2021). Deep learning for visualization and novelty detection in large X-ray diffraction datasets. *Npj Computational Materials*, 7(1), 1–6.
- Barszcz, T. (2019). *Vibration-based condition monitoring of wind turbines*. Springer.
- Bengio, Y., Courville, A. & Vincent, P. (2013). Representation learning : A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798–1828.
- Beretta, M., Julian, A., Sepulveda, J., Cusidó, J. & Porro, O. (2021a). An ensemble learning solution for predictive maintenance of wind turbines main bearing. *Sensors*, 21(4), 1512.
- Beretta, M., Pelka, K., Cusidó, J. & Lichtenstein, T. (2021b). Quantification of the Information Loss Resulting from Temporal Aggregation of Wind Turbine Operating Data. *Applied Sciences*, 11(17), 8065.
- Bonheme, L. & Grzes, M. (2023). How good are variational autoencoders at transfer learning ? *arXiv preprint arXiv :2304.10767*.
- Booyse, W., Wilke, D. N. & Heyns, S. (2020). Deep digital twins for detection, diagnostics and prognostics. *Mechanical Systems and Signal Processing*, 140, 106612. doi : <https://doi.org/10.1016/j.ymssp.2019.106612>.
- Bošnjaković, M., Katinić, M., Santa, R. & Marić, D. (2022). Wind turbine technology trends. *Applied Sciences*, 12(17), 8653.
- Bouchard Bastien, E., Roy Malo, O. & Grenier, G. (2024). Effets sociaux et communautaires et acceptabilité sociale des parcs éoliens. Access le 2024/04/10.
- Bouckaert, S., Pales, A. F., McGlade, C., Remme, U., Wanner, B., Varro, L., D'Ambrosio, D. & Spencer, T. (2021). Net zero by 2050 : A roadmap for the global energy sector.

- Breneman, J. E., Sahay, C. & Lewis, E. E. (2022). *Introduction to reliability engineering*. John Wiley & Sons.
- Cambron, P., Tahan, A., Masson, C. & Pelletier, F. (2017). Bearing temperature monitoring of a wind turbine using physics-based model. *Journal of Quality in Maintenance Engineering*.
- Chadebec, C., Thibeau-Sutre, E., Burgos, N. & Allassonnière, S. (2022). Data augmentation in high dimensional low sample size setting using a geometry-based variational autoencoder. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- Chebel-Morello, B., Nicod, J.-M. & Varnier, C. (2017a). *Du concept de PHM à la maintenance prédictive 2 : Connaissance, traçabilité et décision*. ISTE Group.
- Chebel-Morello, B., Nicod, J.-M. & Varnier, C. (2017b). *From prognostics and health systems management to predictive maintenance 2 : knowledge, reliability and decision*. John Wiley & Sons.
- Chen, T., Liu, X., Xia, B., Wang, W. & Lai, Y. (2020). Unsupervised Anomaly Detection of Industrial Robots Using Sliding-Window Convolutional Variational Autoencoder. *IEEE Access*, 8, 47072-47081. doi : 10.1109/ACCESS.2020.2977892.
- Chen, Z.-Q., Zheng, S.-X., Zhang, J. & Jia, H. (2021). Seismic reliability analysis of high-pier railway bridges with correlated random parameters via an improved maximum entropy method. *Structures*, 33, 4538-4555. doi : <https://doi.org/10.1016/j.istruc.2021.07.039>.
- Cheng, F., Cai, W., Liao, H., Wu, B. & Dubey, S. (2021, Aug). Fault Detection and Isolation for Chiller System based on Deep Autoencoder. *2021 IEEE 16th Conference on Industrial Electronics and Applications (ICIEA)*, pp. 1702-1706. doi : 10.1109/ICIEA51954.2021.9516436.
- Cheng, F., He, Q. P. & Zhao, J. (2019). A novel process monitoring approach based on variational recurrent autoencoder. *Computers & Chemical Engineering*, 129, 106515. doi : <https://doi.org/10.1016/j.compchemeng.2019.106515>.
- Cheng, R.-C. & Chen, K.-S. (2022). Ball bearing multiple failure diagnosis using feature-selected autoencoder model. *The International Journal of Advanced Manufacturing Technology*, 120(7), 4803–4819.
- Cofre-Martel, S., Lopez Drogue, E. & Modarres, M. (2021). Remaining useful life estimation through deep learning partial differential equation models : A framework for degradation dynamics interpretation using latent variables. *Shock and Vibration*, 2021, 1–15.

- Coraça, E. M., Ferreira, J. V. & Nóbrega, E. G. (2023). An unsupervised structural health monitoring framework based on Variational Autoencoders and Hidden Markov Models. *Reliability Engineering & System Safety*, 231, 109025. doi : <https://doi.org/10.1016/j.ress.2022.109025>.
- Costa, Á. M., Orosa, J. A., Vergara, D. & Fernández-Arias, P. (2021). New tendencies in wind energy operation and maintenance. *Applied Sciences*, 11(4), 1386.
- Costa, N. & Sánchez, L. (2022). Variational encoding approach for interpretable assessment of remaining useful life estimation. *Reliability Engineering & System Safety*, 222, 108353.
- Cummins, L., Sommers, A., Ramezani, S. B., Mittal, S., Jabour, J., Seale, M. & Rahimi, S. (2024). Explainable Predictive Maintenance : A Survey of Current Methods, Challenges and Opportunities. *arXiv preprint arXiv :2401.07871*.
- Daems, P.-J., Guo, Y., Sheng, S., Peeters, C., Guillaume, P. & Helsen, J. (2020). Gaining Insights in Loading Events for Wind Turbine Drivetrain Prognostics. *Turbo Expo : Power for Land, Sea, and Air*, 84249, V012T42A010.
- Dao, C., Kazemtabrizi, B. & Crabtree, C. (2019). Wind turbine reliability data review and impacts on levelised cost of energy. *Wind Energy*, 22(12), 1848–1871.
- Davis, N. N., Byrkjedal, Ø., Hahmann, A. N., Clausen, N.-E. & Žagar, M. (2016). Ice detection on wind turbines using the observed power curve. *Wind Energy*, 19(6), 999–1010.
- De Angelis, M. & Gray, A. (2021). Why the 1-Wasserstein distance is the area between the two marginal CDFs. *arXiv preprint arXiv :2111.03570*.
- Deng, L. (2012). The mnist database of handwritten digit images for machine learning research [best of the web]. *IEEE signal processing magazine*, 29(6), 141–142.
- Der Kiureghian, A. & Liu, P.-L. (1986). Structural reliability under incomplete probability information. *Journal of Engineering Mechanics*, 112(1), 85–104.
- DNV. (2022a). *Energy Transition Outlook 2022 : a global and regional forecast to 2050*. Høvik, Norway.
- DNV. (2022b). *Energy transition outlook 2022 - A global and regional forecast to 2050*. Hovik, Norway : DNV.
- DNV. (2023). *Energy Transition Outlook 2023 : a global and regional forecast to 2050*. Høvik, Norway.

- DNV, G. (2020). Energy Transition Outlook 2020-A global and regional forecast to 2050. *Dnv Gl Energy Transit. Outlook*, 306.
- DNV-GL. (2021). *Energy Transition Outlook 2021 : Pathway To Net Zero Emissions*. Høvik, Norway : Det Norske Veritas Group.
- Dodge, S. & Karam, L. (2017). A study and comparison of human and deep learning recognition performance under visual distortions. *2017 26th international conference on computer communication and networks (ICCCN)*, pp. 1–7.
- Doersch, C. (2016). Tutorial on variational autoencoders. *arXiv preprint arXiv :1606.05908*.
- Doss-Gollin, J., Farnham, D. J., Lall, U. & Modi, V. (2021). How unprecedented was the February 2021 Texas cold snap? *Environmental Research Letters*, 16(6), 064056.
- Elforjani, M. (2020). Diagnosis and prognosis of real world wind turbine gears. *Renewable Energy*, 147, 1676–1693.
- Ezukwoke, K., Hoayek, A., Batton-Hubert, M. & Boucher, X. (2022). GCVAE : Generalized-Controllable Variational AutoEncoder. *arXiv preprint arXiv :2206.04225*.
- Feng, C., Liu, C. & Jiang, D. (2023). Unsupervised anomaly detection using graph neural networks integrated with physical-statistical feature fusion and local-global learning. *Renewable Energy*, 206, 309–323.
- Frederick, D. K., DeCastro, J. A. & Litt, J. S. (2007). *User's guide for the commercial modular aero-propulsion system simulation (C-MAPSS)*.
- Gao, L., Tao, T., Liu, Y. & Hu, H. (2021). A field study of ice accretion and its effects on the power production of utility-scale wind turbines. *Renewable energy*, 167, 917–928.
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow : Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media.
- Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. " O'Reilly Media, Inc.".
- Gilpin, L. H., Bau, D., Yuan, B. Z., Bajwa, A., Specter, M. & Kagal, L. (2018). Explaining explanations : An overview of interpretability of machine learning. *2018 IEEE 5th International Conference on data science and advanced analytics (DSAA)*, pp. 80–89.

- González-Muñiz, A., Diaz, I., Cuadrado, A. A. & García-Pérez, D. (2022). Health indicator for machine condition monitoring built in the latent space of a deep autoencoder. *Reliability Engineering & System Safety*, 224, 108482.
- Gouriveau, R., Medjaher, K. & Zerhouni, N. (2016). *From prognostics and health systems management to predictive maintenance 1 : Monitoring and prognostics*. John Wiley & Sons.
- Gouriveau, R., Medjaher, K. & Zerhouni, N. (2017). *Du concept de PHM à la maintenance prédictive 1 : Surveillance et pronostic*. ISTE Group.
- Goutte, C. & Gaussier, E. (2005). A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. *European conference on information retrieval*, pp. 345–359.
- Guo, P. & Infield, D. (2021). Wind turbine blade icing detection with multi-model collaborative monitoring method. *Renewable Energy*, 179, 1098–1105.
- Guo, Y., Thomson, A., Bankestrom, O., Erskine, J., Keller, J. & Bergua, R. (2023). *Operating Conditions of a Main Bearing Contact in a Commercial Wind Turbine*.
- Helbing, G. & Ritter, M. (2018). Deep Learning for fault detection in wind turbines. *Renewable and Sustainable Energy Reviews*, 98, 189–198.
- Hemmer, M., Klausen, A., Van Khang, H., Robbersmyr, K. G. & Waag, T. I. (2020). Health indicator for low-speed axial bearings using variational autoencoders. *IEEE Access*, 8, 35842–35852.
- Hendrycks, D. & Gimpel, K. (2016). A baseline for detecting misclassified and out-of-distribution examples in neural networks. *arXiv preprint arXiv :1610.02136*.
- Herbert, G. J., Iniyan, S., Sreevalsan, E. & Rajapandian, S. (2007). A review of wind energy technologies. *Renewable and sustainable energy Reviews*, 11(6), 1117–1145.
- Higgins, I., Matthey, L., Pal, A., Burgess, C., Glorot, X., Botvinick, M., Mohamed, S. & Lerchner, A. (2016). beta-vae : Learning basic visual concepts with a constrained variational framework.
- Hochart, C., Fortin, G., Perron, J. & Ilinca, A. (2008). Wind turbine performance under icing conditions. *Wind Energy : An International Journal for Progress and Applications in Wind Power Conversion Technology*, 11(4), 319–333.

- Hong, D., Bang, S. & Kim, B. (2021). Unsupervised Condition Diagnosis of Linear Motion Guide Using Generative Model Based on Images. *IEEE Access*, 9, 80491-80499. doi : 10.1109/ACCESS.2021.3084602.
- Hydro-Québec. [Accès le 1 juin 2024]. (2023). Vers un Québec décarboné et prospère – Plan d’action 2035. Repéré à <https://www.hydroquebec.com/data/a-propos/pdf/plan-action-2035.pdf>.
- Hydro-Québec. [Accès le 1 juin 2024]. (2024). Tracer la voie vers une réussite collective - Stratégie de développement éolien. Repéré à <https://www.hydroquebec.com/a-propos/publications-rapports/plan-action-2035.html>.
- Ibrahim, R., Zemouri, R., Kedjar, B., Merkhouf, A., Tahan, A., Al-Haddad, K. et al. (2023). Non-invasive detection of rotor inter-turn short circuit of a hydrogenerator using AI-based variational autoencoder. *IEEE Transactions on Industry Applications*.
- Ibrahim, R., Zemouri, R., Tahan, A., Kedjar, B., Merkhouf, A. & Al-Haddad, K. (2024). Fault detection based on vibration measurements and variational autoencoder-desirability function. *IEEE Open Journal of Industry Applications*.
- IEA. (2021). How Energy Efficiency Will Power Net Zero Climate Goals. *IEA Commentaries*. Repéré à <https://www.iea.org/commentaries/how-energy-efficiency-will-power-net-zero-climate-goals>.
- IEA. (2023). World Energy Outlook. International Energy Agency (IEA).
- IEC. (2022). *Wind energy generation systems - Part 12-1 : Power performance measurement of electricity producing wind turbines*. Geneva, Switzerland.
- Jiang, G., Xie, P., He, H. & Yan, J. (2017). Wind Turbine Fault Detection Using a Denoising Autoencoder With Temporal Information. *IEEE-ASME Transactions on Mechatronics*. doi : 10.1109/tmech.2017.2759301.
- Kaewniam, P., Cao, M., Alkayem, N. F., Li, D. & Manoach, E. (2022). Recent advances in damage detection of wind turbine blades : A state-of-the-art review. *Renewable and Sustainable Energy Reviews*, 167, 112723.
- Keller, J., Sheng, S., Guo, Y., Gould, B. & Greco, A. (2021). *Wind turbine drivetrain reliability and wind plant operations and maintenance research and development opportunities*.
- Khazaeli Moghadam, F., Gao, Z., Chabaud, V. & Chapaloglou, S. (2024). Yaw misalignment in powertrain degradation modeling for wind farm control in curtailed conditions. *Frontiers in Energy Research*, 11, 1272967.

- Kim, K., Parthasarathy, G., Uluyol, O., Foslien, W., Sheng, S. & Fleming, P. (2011). Use of SCADA data for failure detection in wind turbines. *Energy sustainability*, 54686, 2071–2079.
- Kingma, D. P. & Ba, J. (2014). Adam : A method for stochastic optimization. *arXiv preprint arXiv :1412.6980*.
- Kingma, D. P. & Welling, M. (2014). Auto-encoding variational bayes. *International Conference on Learning Representations*.
- Kingma, D. P., Welling, M. et al. (2019). An introduction to variational autoencoders. *Foundations and Trends® in Machine Learning*, 12(4), 307–392.
- Kingma, D. (2017). *Variational inference & deep learning : A new synthesis*. (Thèse de doctorat, Faculty of Science (FNWI), Informatics Institute (IVI), University of Amsterdam). Repéré à <https://hdl.handle.net/11245.1/8e55e07f-e4be-458f-a929-2f9bc2d169e8>.
- Kingma, D. P., Mohamed, S., Jimenez Rezende, D. & Welling, M. (2014). Semi-supervised learning with deep generative models. *Advances in neural information processing systems*, 27.
- Kong, H. B., Jo, S.-H., Jung, J. H., Ha, J. M., Shin, Y. C., Yoon, H., Sun, K. H., Seo, Y.-H. & Jeon, B. C. (2020). A hybrid approach of data-driven and physics-based methods for estimation and prediction of fatigue crack growth. *International Journal of Prognostics and Health Management*, 11, 1–12.
- Kong, X., Jiang, X., Zhang, B., Yuan, J. & Ge, Z. (2022). Latent variable models in the era of industrial big data : Extension and beyond. *Annual Reviews in Control*, 54, 167-199. doi : <https://doi.org/10.1016/j.arcontrol.2022.09.005>.
- Krishnaiah, P., Hagis,Jr, P. & Steinberg, L. (1963). A note on the bivariate chi distribution. *SIAM review*, 5(2), 140–144.
- Le, B. & Andrews, J. (2016). Modelling wind turbine degradation and maintenance. *Wind Energy*, 19(4), 571–591.
- Lebranchu, A., Charbonnier, S., Bérenguer, C. & Frédéric, P. (2014). Using SCADA data for fault detection in wind turbines : local internal model vs distance to a wind farm reference. *CMMNO 2014-4th International Conference on Condition Monitoring of Machinery in Non-Stationary Operations*, pp. Paper-43881.

- Lebrun, R. & Dutfoy, A. (2009). An innovating analysis of the Nataf transformation from the copula viewpoint. *Probabilistic Engineering Mechanics*, 24(3), 312–320.
- Lee, J.-G., Jun, S., Cho, Y.-W., Lee, H., Kim, G. B., Seo, J. B. & Kim, N. (2017). Deep learning in medical imaging : general overview. *Korean journal of radiology*, 18(4), 570.
- Lee, S., Kwak, M., Tsui, K.-L. & Kim, S. B. (2019). Process monitoring using variational autoencoder for high-dimensional nonlinear processes. *Engineering Applications of Artificial Intelligence*, 83, 13 - 27. doi : <https://doi.org/10.1016/j.engappai.2019.04.013>.
- Lei, J., Liu, C. & Jiang, D. (2019). Fault diagnosis of wind turbine based on Long Short-term memory networks. *Renewable energy*, 133, 422–432.
- Leite, G. d. N. P., Araújo, A. M. & Rosas, P. A. C. (2018). Prognostic techniques applied to maintenance of wind turbines : a concise and specific review. *Renewable and Sustainable Energy Reviews*, 81, 1917–1925.
- Li, H., Lü, Z. & Yuan, X. (2008). Nataf transformation based point estimate method. *Chinese Science Bulletin*, 53(17), 2586–2592.
- Li, J., Wang, G., Li, Z., Yang, S., Chong, W. T. & Xiang, X. (2020). A review on development of offshore wind energy conversion system. *International Journal of Energy Research*, 44(12), 9283–9297.
- Li, Y., Jiang, W., Zhang, G. & Shu, L. (2021). Wind turbine fault diagnosis based on transfer learning and convolutional autoencoder with small-scale data. *Renewable Energy*, 171, 103–115.
- Liang, X., Duan, F., Bennett, I. & MBA, D. (2020). A Sparse Autoencoder-Based Unsupervised Scheme for Pump Fault Detection and Isolation. *Applied Sciences*, 10(19). doi : 10.3390/app10196789.
- Liao, W., Bak-Jensen, B., Pillai, J. R., Wang, Y. & Wang, Y. (2021). A review of graph neural networks and their applications in power systems. *Journal of Modern Power Systems and Clean Energy*, 10(2), 345–360.
- Lipton, Z. C. (2018). The mythos of model interpretability : In machine learning, the concept of interpretability is both important and slippery. *Queue*, 16(3), 31–57.
- Liu, J., Wang, X., Xie, F., Wu, S. & Li, D. (2023). Condition monitoring of wind turbines with the implementation of spatio-temporal graph neural network. *Engineering Applications of Artificial Intelligence*, 121, 106000.

- Liu, X., Teng, W., Wu, S., Wu, X., Liu, Y. & Ma, Z. (2021a). Sparse dictionary learning based adversarial variational auto-encoders for fault identification of wind turbines. *Measurement*, 183, 109810. doi : <https://doi.org/10.1016/j.measurement.2021.109810>.
- Liu, X., Teng, W., Wu, S., Wu, X., Liu, Y. & Ma, Z. (2021b). Sparse dictionary learning based adversarial variational auto-encoders for fault identification of wind turbines. *Measurement*, 183, 109810.
- Liu, X., Cao, Z. & Zhang, Z. (2021c). Short-term predictions of multiple wind turbine power outputs based on deep neural networks with transfer learning. *Energy*, 217, 119356.
- Louizos, C. & Welling, M. (2017). Multiplicative normalizing flows for variational bayesian neural networks. *International Conference on Machine Learning*, pp. 2218–2227.
- Maldonado-Correa, J., Martín-Martínez, S., Artigao, E. & Gómez-Lázaro, E. (2020). Using SCADA data for wind turbine condition monitoring : A systematic literature review. *Energies*, 13(12), 3132.
- Márquez, F. P. G. & Chacón, A. M. P. (2020). A review of non-destructive testing on wind turbines blades. *Renewable Energy*, 161, 998–1010.
- Marti-Puig, P., Blanco-M, A., Cárdenas, J. J., Cusidó, J. & Solé-Casals, J. (2018). Effects of the pre-processing algorithms in fault diagnosis of wind turbines. *Environmental modelling & software*, 110, 119–128.
- Masood, A. & Ahmad, K. (2021). A review on emerging artificial intelligence (AI) techniques for air pollution forecasting : Fundamentals, application and performance. *Journal of Cleaner Production*, 322, 129072.
- Masson-Delmotte, V., Zhai, P., Pörtner, H., Roberts, D., Skea, J., Shukla, P., Pirani, A., Moufouma-Okia, W., Péan, C., Pidcock, R., Connors, S., Matthews, J., Chen, Y., Zhou, X., Gomis, M., Lonnoy, E., Maycock, T., Tignor, M. & Waterfield, T. (2018). Special Report : Global Warming of 1.5 °C. Intergovernmental Panel on Climate Change (IPCC).
- Mathieu, E., Rainforth, T., Siddharth, N. & Teh, Y. W. (2019). Disentangling disentanglement in variational autoencoders. *International Conference on Machine Learning*, pp. 4402–4412.
- May, A., McMillan, D. & Thöns, S. (2015). Economic analysis of condition monitoring systems for offshore wind turbine sub-systems. *IET Renewable Power Generation*, 9(8), 900–907.
- McKenna, R., vd Leye, P. O. & Fichtner, W. (2016). Key challenges and prospects for large wind turbines. *Renewable and Sustainable Energy Reviews*, 53, 1212–1221.

- Miele, E. S., Bonacina, F. & Corsini, A. (2022). Deep anomaly detection in horizontal axis wind turbines using graph convolutional autoencoders for multivariate time series. *Energy and AI*, 8, 100145.
- MIMOSA. (2006). Open System Architecture for Condition-Based Maintenance. Repéré à <https://www.mimosa.org/mimosa-osa-cbm>.
- Multon, B., Gergaud, O., Ahmed, H. B., Roboam, X., Astier, S., Dakyo, B. & Nikita, C. (2002). Etat de l'art des aérogénérateurs. Ed. NOVELECT-ECRIN, ISBN 2-912154-8-1.
- Naitzat, G., Zhitnikov, A. & Lim, L.-H. (2020). Topology of deep neural networks. *Journal of Machine Learning Research*, 21(184), 1–40.
- Nalisnick, E., Matsukawa, A., Teh, Y. W., Gorur, D. & Lakshminarayanan, B. (2018). Do deep generative models know what they don't know? *arXiv preprint arXiv:1810.09136*.
- Nataf, A. (1962). Détermination des distributions de probabilités dont les marges sont données. *Comptes Rendus de l'Académie des Sciences, A* 225(42-3).
- Nguyen, K. T., Medjaher, K. & Tran, D. T. (2023). A review of artificial intelligence methods for engineering prognostics and health management with implementation guidelines. *Artificial Intelligence Review*, 56(4), 3659–3709.
- Nicod, J.-M., Chebel-Morello, B. & Varnier, C. (2017). *From prognostics and health systems management to predictive maintenance 2 : knowledge, reliability and decision*. John Wiley & Sons.
- Niu, G. et al. (2017). Data-driven technology for engineering systems health management. *Springer Singapore*, 10, 978–981.
- Oliveira-Filho, A., Zemouri, R., Cambron, P. & Tahan, A. (2023). Early Detection and Diagnosis of Wind Turbine Abnormal Conditions Using an Interpretable Supervised Variational Autoencoder Model. *Energies*, 16(12), 4544.
- Oliveira-Filho, A., Zemouri, R., Pelletier, F. & Tahan, A. (2024). System Condition Monitoring Based on a Standardized Latent Space and the Nataf Transform. *IEEE Access*.
- Oliveira-Filho, A. M. d., Cambron, P. & Tahan, A. (2022). Condition Monitoring of Wind Turbine Main Bearing Using SCADA Data and Informed by the Principle of Energy Conservation. *2022 Prognostics and Health Management Conference (PHM-2022 London)*, pp. 276–282.

- Oyague, F. (2011). *Gearbox Reliability Collaborative (GRC) Description and Loading* (Rapport n°NREL/TP-5000-47773).
- Pandit, R. & Wang, J. (2024). A comprehensive review on enhancing wind turbine applications with advanced SCADA data analytics and practical insights. *IET Renewable Power Generation*.
- Pandit, R., Astolfi, D., Hong, J., Infield, D. & Santos, M. (2022). SCADA data for wind turbine data-driven condition/performance monitoring : A review on state-of-art, challenges and future trends. *Wind Engineering*, 1, 20.
- Pandiyani, V., Prost, J., Vorlauffer, G., Varga, M. & Wasmer, K. (2021). Identification of abnormal tribological regimes using a microphone and semi-supervised machine-learning algorithm. *Friction*.
- Park, S., Adosoglou, G. & Pardalos, P. M. (2021). Interpreting rate-distortion of variational autoencoder and using model uncertainty for anomaly detection. *Annals of Mathematics and Artificial Intelligence*, 1–18.
- Patro, S. & Sahu, K. K. (2015). Normalization : A preprocessing stage. *arXiv preprint arXiv :1503.06462*.
- Peeters, C., Guillaume, P. & Helsen, J. (2018). Vibration-based bearing fault detection for operations and maintenance cost reduction in wind energy. *Renewable Energy*, 116, 74–87.
- Proteau, A., Zemouri, R., Tahan, A. & Thomas, M. (2020). Dimension reduction and 2D-visualization for early change of state detection in a machining process with a variational autoencoder approach. *The International Journal of Advanced Manufacturing Technology*, 111(11), 3597–3611.
- Proteau, A., Zemouri, R., Tahan, A., Thomas, M., Bounouara, W. & Agnard, S. (2022). CNC machining quality prediction using variational autoencoder : A novel industrial 2 TB dataset.
- Proteau, A., Tahan, A., Zemouri, R. & Thomas, M. (2023). Predicting the quality of a machined workpiece with a variational autoencoder approach. *Journal of Intelligent Manufacturing*, 34(2), 719–737.
- Pujari, P. C., Jain, A., Nath, D. S. & Kumar, N. (2021). Performance enhancement of savonius turbine with the application of reorienting blade mechanism. *Energy Sources, Part A : Recovery, Utilization, and Environmental Effects*, 1–18.

- Ramakrishna, S., Rahiminasab, Z., Karsai, G., Easwaran, A. & Dubey, A. (2022). Efficient out-of-distribution detection using latent space of  $\beta$ -vae for cyber-physical systems. *ACM Transactions on Cyber-Physical Systems (TCPS)*, 6(2), 1–34.
- Ramasso, E. & Saxena, A. (2014). Performance Benchmarking and Analysis of Prognostic Methods for CMAPSS Datasets. *International Journal of Prognostics and Health Management*, 5(2), 1–15.
- Ramdas, A., García Trillo, N. & Cuturi, M. (2017). On wasserstein two-sample testing and related families of nonparametric tests. *Entropy*, 19(2), 47.
- Renström, N., Bangalore, P. & Highcock, E. (2020). System-wide anomaly detection in wind turbines using deep autoencoders. *Renewable Energy*. doi : 10.1016/j.renene.2020.04.148.
- Ressources naturelles Canada. [Access le 2024/01/20]. (2024). Base de données canadienne sur les éoliennes [L'emplacement géographique et les principaux détails technologiques des éoliennes installées au Canada depuis 1993/01/01.]. Repéré à <https://open.canada.ca/data/en/dataset/79fdad93-9025-49ad-ba16-c26d718cc070>.
- Rezamand, M., Kordestani, M., Cariveau, R., Ting, D. S.-K., Orchard, M. E. & Saif, M. (2020a). Critical wind turbine components prognostics : A comprehensive review. *IEEE Transactions on Instrumentation and Measurement*, 69(12), 9306–9328.
- Rezamand, M., Kordestani, M., Orchard, M. E., Cariveau, R., Ting, D. S.-K. & Saif, M. (2020b). Improved remaining useful life estimation of wind turbine drivetrain bearings under varying operating conditions. *IEEE Transactions on Industrial Informatics*, 17(3), 1742–1752.
- Roberts, S. (1959). Control Chart Tests Based on Geometric Moving Averages. *Technometrics*, 1(3), 239–250.
- Roelofs, C. M., Lutz, M.-A., Faulstich, S. & Vogt, S. (2021). Autoencoder-based anomaly root cause analysis for wind turbines. *Energy and AI*, 4, 100065.
- Santelo, T. N., de Oliveira, C. M. R., Maciel, C. D. & de A. Monteiro, J. R. B. (2021). Wind turbine failures review and trends. *Journal of Control, Automation and Electrical Systems*, 1–17.

Santiago, R. A. d. F., Barbosa, N. B., Mergulhão, H. G., Carvalho, T. F. d., Santos, A. A. B., Medrado, R. C., Filho, J. B. d. M., Pinheiro, O. R. & Nascimento, E. G. S. (2024). Data-Driven Models Applied to Predictive and Prescriptive Maintenance of Wind Turbine : A Systematic Review of Approaches Based on Failure Detection, Diagnosis, and Prognosis. *Energies*, 17(5), 1010.

Saxena, A., Goebel, K., Simon, D. & Eklund, N. (2008). Damage propagation modeling for aircraft engine run-to-failure simulation. *2008 international conference on prognostics and health management*, pp. 1–9.

Shah, K. A., Meng, F., Li, Y., Nagamune, R., Zhou, Y., Ren, Z. & Jiang, Z. (2021). A synthesis of feasible control methods for floating offshore wind turbine system dynamics. *Renewable and Sustainable Energy Reviews*, 151, 111525.

Shahid, N. & Ghosh, A. (2019). TrajecNets : Online failure evolution analysis in 2D space. *International Journal of Prognostics and Health Management*, 10(4).

Silverman, B. W. (2018). *Density estimation for statistics and data analysis*. Routledge.

Smil, V. (2007). The two prime movers of globalization : history and impact of diesel engines and gas turbines. *Journal of Global History*, 2(3), 373–394.

Smil, V. (2018). *Energy and civilization : a history*. MIT press.

Sohn, K., Lee, H. & Yan, X. (2015). Learning structured output representation using deep conditional generative models. *Advances in neural information processing systems*, 28.

Song, X., Bührer, C., Mølgaard, A., Andersen, R. S., Brutsaert, P., Bauer, M., Hansen, J., Rebsdorf, A. V., Kellers, J., Winkler, T. et al. (2020). Commissioning of the world's first full-scale MW-class superconducting generator on a direct drive wind turbine. *IEEE Transactions on Energy Conversion*, 35(3), 1697–1704.

StackExchange-Contributors. [Accessed : 2024-04-29]. (2018). What is the difference between a neural network and a deep neural network and why the deep network performs better ? Repéré à <https://stats.stackexchange.com/questions/182734/what-is-the-difference-between-a-neural-network-and-a-deep-neural-network-and-w>.

Stetco, A., Dinmohammadi, F., Zhao, X., Robu, V., Flynn, D., Barnes, M., Keane, J. & Nenadic, G. (2019). Machine learning methods for wind turbine condition monitoring : A review. *Renewable energy*, 133, 620–635.

- Sundar, V. K., Ramakrishna, S., Rahiminasab, Z., Easwaran, A. & Dubey, A. (2020). Out-of-distribution detection in multi-label datasets using latent space of  $\beta$ -vae. *2020 IEEE Security and Privacy Workshops (SPW)*, pp. 250–255.
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C. & Liu, C. (2018). A survey on deep transfer learning. *Artificial Neural Networks and Machine Learning–ICANN 2018 : 27th International Conference on Artificial Neural Networks, Rhodes, Greece, October 4-7, 2018, Proceedings, Part III* 27, pp. 270–279.
- Tang, P., Peng, K., Dong, J., Zhang, K. & Zhao, S. (2020). Monitoring of Nonlinear Processes With Multiple Operating Modes Through a Novel Gaussian Mixture Variational Autoencoder Model. *IEEE Access*, 8, 114487-114500. doi : 10.1109/ACCESS.2020.3003095.
- Tanner, M. A. & Wong, W. H. (1987). The calculation of posterior distributions by data augmentation. *Journal of the American statistical Association*, 82(398), 528–540.
- Tautz-Weinert, J. & Watson, S. J. (2017). Using SCADA data for wind turbine condition monitoring—a review. *IET Renewable Power Generation*, 11(4), 382–394.
- Tits, N., Wang, F., Haddad, K. E., Pagel, V. & Dutoit, T. (2019). Visualization and interpretation of latent spaces for controlling expressive speech synthesis through audio analysis. *arXiv preprint arXiv :1903.11570*.
- Tschannen, M., Bachem, O. & Lucic, M. Recent advances in autoencoder-based representation learning. *arXiv 2018. arXiv preprint arXiv :1812.05069*.
- Tschannen, M., Bachem, O. & Lucic, M. (2018). Recent advances in autoencoder-based representation learning. *arXiv preprint arXiv :1812.05069*.
- UpWind, N. (2011). Design limits and solutions for very large wind turbines. *EWEA, Brussels, Belgium*.
- Valamanesh, V., Myers, A. & Arwade, S. (2015). Multivariate analysis of extreme metocean conditions for offshore wind turbines. *Structural Safety*, 55, 60-69. doi : <https://doi.org/10.1016/j.strusafe.2015.03.002>.
- Veers, P., Kroposki, B., Novacheck, J., Gevorgian, V., Laird, D., Zhang, Y., Corbus, D., Baggu, M., Palmintier, B. & Dhulipala, S. (2021). *Examination of the Extreme Cold Weather Event Affecting the Power System in Texas-February 2021*.

- Veers, P., Bottasso, C., Manuel, L., Naughton, J., Pao, L., Paquette, J., Robertson, A., Robinson, M., Ananthan, S., Barlas, A. et al. (2022). Grand challenges in the design, manufacture, and operation of future wind turbine systems. *Wind Energy Science Discussions*, 2022, 1–102.
- Vichare, N. M. & Pecht, M. G. (2006). Prognostics and health management of electronics. *IEEE transactions on components and packaging technologies*, 29(1), 222–229.
- Wang, K., Forbes, M. G., Gopaluni, B., Chen, J. & Song, Z. (2019a). Systematic Development of a New Variational Autoencoder Model Based on Uncertain Data for Monitoring Nonlinear Processes. *IEEE Access*, 7, 22554–22565. doi : 10.1109/ACCESS.2019.2894764.
- Wang, L., Zhang, Z., Xu, J. & Liu, R. (2018). Wind Turbine Blade Breakage Monitoring With Deep Autoencoders. *IEEE Transactions on Smart Grid*. doi : 10.1109/tsg.2016.2621135.
- Wang, Y., Hu, Q., Li, L., Foley, A. M. & Srinivasan, D. (2019b). Approaches to wind power curve modeling : A review and discussion. *Renewable and Sustainable Energy Reviews*, 116, 109422.
- Wu, X., Jiang, G., Wang, X., Xie, P., Li, X. & Li, X. (2019). A Multi-Level-Denoising Autoencoder Approach for Wind Turbine Fault Detection. *IEEE Access*. doi : 10.1109/access.2019.2914731.
- Yang, L. & Zhang, Z. (2021). Wind Turbine Gearbox Failure Detection Based on SCADA Data : A Deep Learning-Based Approach. *IEEE Transactions on Instrumentation and Measurement*, 70, 1-11. doi : 10.1109/TIM.2020.3045800.
- Yang, W., Tavner, P. J., Crabtree, C. J., Feng, Y. & Qiu, Y. (2014). Wind turbine condition monitoring : technical and commercial challenges. *Wind energy*, 17(5), 673–693.
- Yang, Z., Baraldi, P. & Zio, E. (2021). A multi-branch deep neural network model for failure prognostics based on multimodal data. *Journal of Manufacturing Systems*, 59, 42–50.
- Yuan, B., Yuan, B., Wang, C., Luo, C., Luo, C., Jiang, F., Jiang, F., Long, M., Yu, P. S. & Liu, Y. (2019). WaveletAE : A Wavelet-enhanced Autoencoder for Wind Turbine Blade Icing Detection. *arXiv : Learning*. doi : null.
- Yucesan, Y. A. & Viana, F. A. (2020a). ‘A physics-informed neural network for wind turbine main bearing fatigue. *International Journal of Prognostics and Health Management*, 11(1), 17.

- Yucesan, Y. A. & Viana, F. A. (2022). A hybrid physics-informed neural network for main bearing fatigue prognosis under grease quality variation. *Mechanical Systems and Signal Processing*, 171, 108875.
- Yucesan, Y. A. & Viana, F. (2020b). A Hybrid Model for Wind Turbine Main Bearing Fatigue with Uncertainty in Grease Observations. *Annual Conference of the PHM Society*, 12(1), 14–14.
- Yue, R., Jiang, G., Jin, X., He, Q. & Xie, P. (2024). Spatio-Temporal Feature Alignment Transfer Learning for Cross-Turbine Blade Icing Detection of Wind Turbines. *IEEE Transactions on Instrumentation and Measurement*.
- Zemouri, R., Levesque, M., Amyot, N., Hudon, C., Kokoko, O. & Tahan, S. A. (2019). Deep convolutional variational autoencoder as a 2D-visualization tool for partial discharge source classification in hydrogenerators. *IEEE Access*, 8, 5438–5454.
- Zemouri, R., Lévesque, M., Boucher, É., Kirouac, M., Lafleur, F., Bernier, S. & Merkhouf, A. (2022). Recent Research and Applications in Variational Autoencoders for Industrial Prognosis and Health Management : A Survey. *2022 Prognostics and Health Management Conference (PHM-2022 London)*, pp. 193–203.
- Zemouri, R., Ibrahim, R. & Tahan, A. (2023). Hydrogenerator early fault detection : Sparse Dictionary Learning jointly with the Variational Autoencoder. *Engineering Applications of Artificial Intelligence*, 120, 105859. doi : <https://doi.org/10.1016/j.engappai.2023.105859>.
- Zeng, H., Dai, J., Zuo, C., Chen, H., Li, M. & Zhang, F. (2022). Correlation Investigation of Wind Turbine Multiple Operating Parameters Based on SCADA Data. *Energies*, 15(14), 5280.
- Zhang, L., Zhang, H. & Cai, G. (2022). The multiclass fault diagnosis of wind turbine bearing based on multisource signal fusion and deep learning generative model. *IEEE Transactions on Instrumentation and Measurement*, 71, 1–12.
- Zhang, S., Ye, F., Wang, B. & Habetler, T. G. (2020). Semi-supervised bearing fault diagnosis and classification using variational autoencoder-based deep generative models. *IEEE Sensors Journal*, 21(5), 6476–6486.
- Zhao, H., Liu, H., Hu, W. & Yan, X. (2018a). Anomaly detection and fault analysis of wind turbine components based on deep learning network. *Renewable Energy*. doi : 10.1016/j.renene.2018.05.024.

- Zhao, H., Liu, H., Hu, W. & Yan, X. (2018b). Anomaly detection and fault analysis of wind turbine components based on deep learning network. *Renewable energy*, 127, 825–834.
- Zhao, Y., Liao, Z. & Dong, S. (2021a). Estimation of characteristic extreme response for mooring system in a complex ocean environment. *Ocean Engineering*, 225, 108809. doi : <https://doi.org/10.1016/j.oceaneng.2021.108809>.
- Zhao, Z., Wu, J., Li, T., Sun, C., Yan, R. & Chen, X. (2021b). Challenges and opportunities of AI-enabled monitoring, diagnosis & prognosis : A review. *Chinese Journal of Mechanical Engineering*, 34(1), 1–29.
- Zheng, M., Man, J., Wang, D., Chen, Y., Li, Q. & Liu, Y. (2023). Semi-supervised multivariate time series anomaly detection for wind turbines using generator SCADA data. *Reliability Engineering & System Safety*, 235, 109235. doi : <https://doi.org/10.1016/j.ress.2023.109235>.
- Zhou, T., Zhang, L., Han, T., Drogue, E. L., Mosleh, A. & Chan, F. T. (2023). An uncertainty-informed framework for trustworthy fault diagnosis in safety-critical applications. *Reliability Engineering & System Safety*, 229, 108865. doi : <https://doi.org/10.1016/j.ress.2022.108865>.
- Zhu, J., Peng, G. & Wang, D. (2020). Dual-domain-based adversarial defense with conditional VAE and Bayesian network. *IEEE Transactions on Industrial Informatics*, 17(1), 596–605.
- Zio, E. (2022). Prognostics and Health Management (PHM) : Where are we and where do we (need to) go in theory and practice. *Reliability Engineering & System Safety*, 218, 108119.
- Zio, E. (2024). Prognostics and Health Management Methods for Reliability Prediction and Predictive Maintenance. *IEEE Transactions on Reliability*.
- Ásgeir Daniel Hallgrímsson, Niemann, H. H. & Lind, M. (2020). Improved Process Diagnosis Using Fault Contribution Plots from Sparse Autoencoders. *IFAC-PapersOnLine*, 53(2), 730-737. doi : <https://doi.org/10.1016/j.ifacol.2020.12.823>. 21st IFAC World Congress.
- Ásgeir Daniel Hallgrímsson, Niemann, H. H. & Lind, M. (2021). Unsupervised isolation of abnormal process variables using sparse autoencoders. *Journal of Process Control*, 99, 107-119. doi : <https://doi.org/10.1016/j.jprocont.2021.01.005>.