



HAL
open science

Usage de la simulation pour valider des algorithmes d'optimisation de maintenance

Marcel Chevalier, Léo Dupont, Sylvain Marié, Frédérique Roffet, Elena Stolyarova, William Templier, Costin Vasile

► To cite this version:

Marcel Chevalier, Léo Dupont, Sylvain Marié, Frédérique Roffet, Elena Stolyarova, et al.. Usage de la simulation pour valider des algorithmes d'optimisation de maintenance. 32ème Congrès Lambda Mu, Institut pour la Maîtrise des Risques (IMdR), Oct 2022, Paris Saclay, France. hal-03970682

HAL Id: hal-03970682

<https://hal.science/hal-03970682>

Submitted on 2 Feb 2023

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

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

Usage de la simulation pour valider des algorithmes d'optimisation de maintenance

CHEVALIER Marcel, DUPONT Léo, MARIÉ Sylvain, ROFFET Frédérique,
STOLYAROVA Elena, TEMPLIER William, VASILE Costin

Schneider Electric

Grenoble, IntenCity, 160, Avenue des Martyrs

prénom.nom@se.com

Résumé — Les industries ont un besoin croissant de réduire le risque de défaillances imprévues d'équipements et d'optimiser leurs opérations de maintenance. Chez Schneider Electric, nous proposons d'utiliser des modèles physiques pour l'anticipation du vieillissement à long terme, complétés par des modèles d'apprentissage automatique pour la détection de défauts à court terme. Les modèles physiques sont élaborés en décomposant les systèmes en leurs éléments constitutifs, puis en associant ceux-ci à des modes de dégradation et enfin aux lois cinétiques appropriées. La simulation de ces modèles permet de comparer différentes stratégies de maintenance et d'optimiser celle-ci. Les modèles d'apprentissage automatique sont entraînés de manière incrémentale, à partir d'un échantillon dit « normal », afin de prédire la valeur attendue et de détecter des écarts statistiquement significatifs. Un opérateur humain valide les fautes détectées. La simulation permet de trouver les paramètres optimaux de l'ensemble de cette procédure.

Mots-clefs — *Modèles de dégradation, vieillissement, détection d'anomalies, capteurs virtuels, apprentissage incrémental*

Abstract— Industrial end users are currently facing an increasing need to reduce the risk of unexpected equipment failures and to optimize their maintenance. At Schneider Electric, we suggest using physical models for ageing anticipation, complemented by machine learning models for short term anomaly detection. Physical models are elaborated by decomposing systems into their constitutive components, associating them to degradation modes and finally to appropriate kinetic laws. Simulating these models allows to compare different maintenance strategies and optimize them. Machine learning models are estimated incrementally – from a “normal” data set – in order to predict the expected behavior and detect statistically significant deviation. A human operator confirms the detected faults. Optimal parameters for this entire procedure can be found via simulation.

Keywords— **Degradation models, Ageing, Anomaly detection, Soft Sensor, Incremental learning**

I. INTRODUCTION

La numérisation et l'Internet Industriel des Objets (IIoT) permettent aujourd'hui l'accumulation massive en temps réel de données caractérisant des équipements sur les sites clients au cours de leur durée d'exploitation. Cela permet aux utilisateurs d'obtenir de l'information sur les conditions environnementales ou l'utilisation de leurs équipements en temps réel ; et également sur des situations de défaillance.

Les données collectées peuvent servir à modéliser le comportement normal d'équipement critiques (*critical asset*) et à élaborer des modèles utiles à la détection d'anomalies – caractérisées par un écart statistiquement significatif par rapport à la situation normale. Bien que ce type de méthode de détection d'anomalies soit approprié sur des périodes de court terme, il ne l'est pas pour détecter des formes de dégradation se manifestant sur plusieurs années, voire des décennies. Afin de capturer de telles tendances, des modèles de dégradation basés sur la physique (*e.g.* la loi d'Arrhenius) peuvent être utilisés pour compléter le système de supervision et ainsi obtenir une vision globale de la santé de l'équipement. Ces deux approches sont présentées en détail dans [1].

La validation de ces approches présente un défi considérable car les données caractérisant des situations de défaillance sont sous-représentées dans les échantillons ; et les tendances de vieillissement des équipements s'observent sur plusieurs années de vie opérationnelle. De plus, des opérations de maintenance, ayant lieu à des moments potentiellement sous-optimaux, réinitialisent partiellement cette dégradation. Enfin, dans l'approche orientée données, l'ajout incrémental de nouvelles données d'apprentissage dans les modèles peut donner lieu à l'injection de données dites « anormales » (*i.e.* faux positifs) ou au contraire, au rejet de données normales (*i.e.* faux négatifs).

La simulation et la validation de modèles de maintenance sont tout d'abord présentées en section II ; puis les modèles incrémentaux basés sur des capteurs virtuels suivent en section III. Nous concluons en section IV.

II. LONG TERME

Dans cette partie, nous faisons référence à une approche à long terme pour calculer le vieillissement des produits en fonction du temps, des conditions environnementales, des conditions d'utilisation et des opérations de maintenance. Ces modèles de vieillissement peuvent être utilisés pour définir une maintenance basée sur les conditions réelles.

Dans les sections suivantes, nous présentons comment ces modèles peuvent être utilisés pour simuler une multitude de systèmes et scénarios de maintenance différents, par exemple la maintenance conditionnelle.

A Approche proposée

Chaque produit connecté est décomposé en sous-ensembles, tous associés à un ou plusieurs modes de dégradation [1]. Ces modes de dégradation sont en compétition pour chaque sous-ensemble concerné. A chaque instant, le mode de dégradation le plus impactant est sélectionné pour chaque sous-ensemble, et le sous-ensemble le plus impacté est utilisé pour calculer la durée de vie consommée. Les opérations de maintenance peuvent remplacer le sous-ensemble le plus impacté par un autre, ou changer le mode de dégradation le plus impactant par un autre.

La Fig. 1 illustre un cycle de simulation pour un produit donné, montrant la durée de vie consommée (%) au fil du temps. Chaque pic est dû à une opération de maintenance ou au remplacement d'un sous-ensemble, qui réinitialisent la valeur de vieillissement.

La première opération de maintenance est effectuée sur le sous-ensemble le plus impacté. Après cet événement, la durée de vie consommée de l'appareil est réduite car le sous-ensemble le plus impacté a été maintenu, son vieillissement repart donc de zéro. Un autre mode de dégradation devient donc le sous-ensemble limitant.

L'analyse d'hypothèses (*what-if analysis*) est définie dans la littérature comme une simulation intensive de données dont les objectifs sont d'inspecter le comportement d'un système complexe [11]. Initialement axés sur les données scalaires, les scénarios d'hypothèses intègrent aujourd'hui de plus en plus de données chronologiques afin d'améliorer la précision de l'analyse [8]. Deux types d'analyse d'hypothèses peuvent être envisagés :

L'analyse de sensibilité : en générant un grand nombre de scénarios, on peut tester la sensibilité des modèles de vieillissement pour les affiner. Cette analyse permet de vérifier et de modifier rapidement les modèles, afin qu'ils soient les plus fiables possibles ;

Analyse de scénarios : il est également possible de générer une multitude de scénarios réalistes permettant de simuler et comparer différents choix pour trouver la solution optimale.

Dans cette étude, nous nous concentrons sur l'analyse de scénarios pour explorer deux dimensions : des contextes d'usage alternatifs (B) et des scénarios de maintenance alternatifs (C).

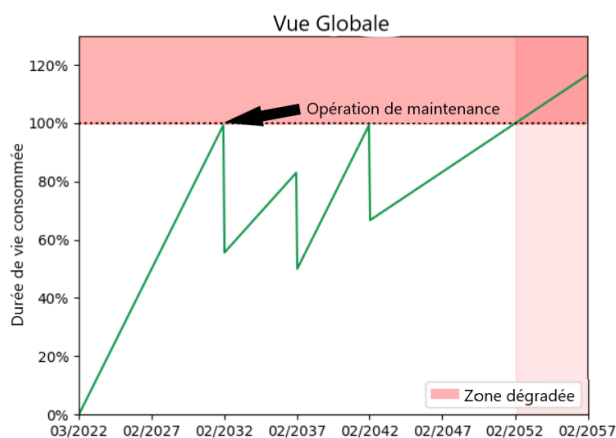


Fig. 2. Simulation à long terme

B Contextes d'usage alternatifs

En modélisant divers scénarios, nous pouvons simuler le processus de vieillissement des équipements dans une perspective à long terme.

Nos simulations des conditions environnementales sont basées sur des données de simulation météorologique [4] afin de fournir les scénarios environnementaux les plus réalistes. Naturellement, ces scénarios dépendent de l'emplacement du site du client, ainsi que de l'utilisation future de nos produits. Nous devons également relier tous les facteurs d'influence et les événements du client. Par exemple, si un client souhaite ajouter un climatiseur, il est possible de simuler l'impact direct sur les entrées environnementales. Dans ce cas, la température reste constante, l'humidité pourrait également être statique, mais il y a des inconvénients possibles comme une augmentation de la poussière due à une nouvelle ventilation. Ainsi, avec une simulation réaliste, nous pouvons évaluer l'impact du climatiseur pour conseiller le client sur ce choix. Un exemple de ce cas est fourni dans la Fig. 2.

C Scénarios de maintenance alternatifs

Concernant la maintenance, les scénarios d'hypothèses permettent d'optimiser la fréquence des plans de maintenance qui peuvent être adaptés à chaque client. Le plus souvent, les plans de maintenance sont extraits de guides de maintenance, basés sur des recommandations de périodicité fixe [9]. L'approche décrite permet de générer des correspondances adéquates pour planifier les opérations de maintenance, et de conseiller nos clients sur le risque pris en omettant la maintenance constructeur. Ceci est possible en simulant les opérations de vie de l'équipement du client, puis en effectuant la maintenance d'un sous-composant uniquement lorsqu'il atteint sa fin de vie en comparant deux scénarios : le plan de maintenance standard et le plan personnalisé en fonction du vieillissement. Nous avons comparé ces deux scénarios dans la Fig. 3, où les effets des actions de maintenance se traduisent sur la courbe par des chutes soudaines de la consommation sur la durée de vie.

D Déploiement sur le terrain

La section précédente sur les scénarios d'hypothèses a décrit comment la simulation aide l'étape de validation, tant en termes de simulation du vieillissement que de scénario de maintenance.

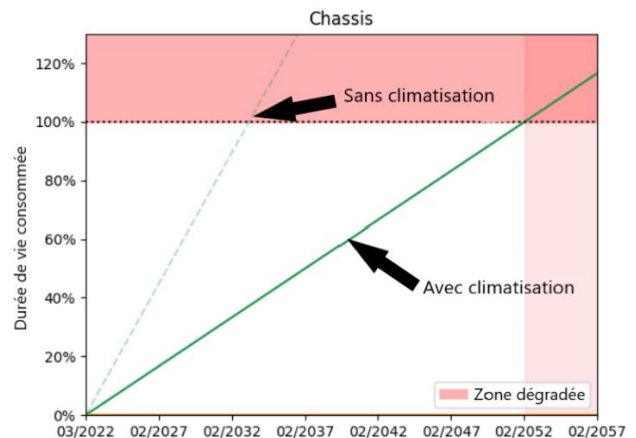


Fig. 1. Impact de la climatisation

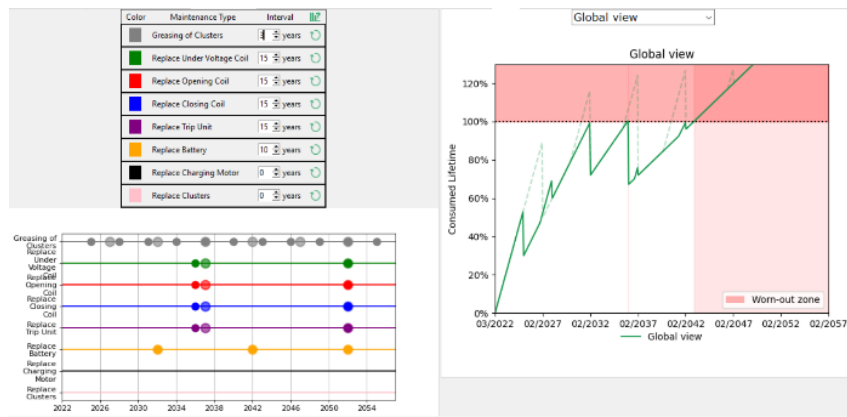


Fig. 3. Impact de la maintenance

Ces processus de simulation permettent de transformer les pratiques de maintenance traditionnelles en une approche de maintenance basée sur l'état. En effet, les recommandations de périodicité des fabricants de maintenance décrites dans les guides de maintenance sont utiles pour fournir une vue d'ensemble de la durée de vie des équipements. Cependant, selon le type de segments (marine, mines-minéraux-métaux, pétrole et gaz, santé, agroalimentaire), les contraintes ne sont pas les mêmes. Deux exemples sont décrits ci-dessous :

- Les clients de la marine ont la contrainte spécifique d'effectuer des actions de maintenance lorsque les bateaux reviennent à quai. La possibilité d'estimer le vieillissement des équipements et les conséquences des actions de maintenance facilite l'anticipation des actions requises, garantissant la confiance dans le comportement de l'équipement en attendant la prochaine maintenance.
- Quel que soit le type de segment, le nombre d'équipements n'est pas le même d'un client à l'autre. Lorsque le nombre d'équipements est élevé, ce type de simulation permet de gérer la maintenance de la flotte en anticipant les conséquences de la reprogrammation de la maintenance pour une partie des équipements.

Par conséquent, la combinaison de la recommandation de périodicité du fabricant et du processus de simulation permet d'adapter les actions de maintenance à chaque client en ajoutant plus de flexibilité, plus d'anticipation de la fin de vie, et en effectuant une maintenance opportune. Cette approche de maintenance conditionnelle rend les opérations plus efficaces tout en rendant l'entreprise plus résiliente et durable [12].

Chez Schneider Electric cette approche est utilisée par des clients de différents segments et pour différents types d'équipements, sur des domaines de basse tension ou de moyenne tension. Dans les deux années à venir, nous prévoyons de doubler le nombre de clients demandant à transformer les pratiques de maintenance traditionnelles en maintenance conditionnelle. En augmentant le nombre d'expériences sur le terrain, nous allons continuellement remettre en question et améliorer les modèles actuels d'estimation du vieillissement, en tirant parti de l'avantage de lier la simulation et la validation en fermant la boucle avec le client, en utilisant ses données pour améliorer les modèles.

III. COURT TERME

La section II montre que l'analyse d'hypothèses peut aider à choisir et valider des actions de maintenance, et ainsi réduire des défaillances à long-terme ou accroître la durée de vie escomptée d'un équipement. La présente section se concentre sur l'analyse à court-terme. Tout d'abord, nous présentons l'approche utilisant un modèle d'apprentissage automatique, nous décrivons ensuite les stratégies d'apprentissage incrémental, et enfin nous concluons sur l'approche à l'aide de résultats expérimentaux.

A. Approche proposée

Les capteurs virtuels (*Soft/Virtual sensors*) sont des modèles d'apprentissage automatique utilisés pour la détection d'anomalies à court terme [1]. Ces capteurs virtuels servent à prédire diverses données industrielles sur la base des conditions d'usage et d'environnement. Ce type de modèle peut soit prédire une catégorie (classification) soit une quantité (régression) ; pour une description plus exhaustive, voir [2]. Outre leur usage en contrôle industriel, les capteurs virtuels sont utilisés en redondance de capteurs physiques, pour l'analyse d'hypothèses, pour la validation de capteurs, et à des fins de détection et de diagnostic de fautes.

Dans ce dernier cas, les données observées sont comparées aux données de référence générées par le capteur virtuel en calculant l'erreur du modèle (les résidus). Les résidus sont ensuite utilisés pour détecter des observations statistiquement aberrantes [5]. La Fig. 4 montre comment le *Virtual Sensor Fault Detection* (VSFD) est assemblé afin de créer un mécanisme de surveillance de la température des connexions électriques.

B. Apprentissage incrémental

1) Contexte

Les capteurs virtuels sont entraînés sur un échantillon historique de données dites « normales » (*i.e.* sans fautes). Cet échantillon couvre une période limitée et probablement un ensemble limité de modes d'opérations normales. Les nouvelles données peuvent donc inclure des comportements normaux jusqu'alors inobservés. Ce problème, connu sous le




Fig. 4. Principe du Virtual Sensor Fault Detection (VSFD)

nom de dérive conceptuelle (*concept drift*), peut entraîner la baisse progressive de la performance du modèle. Pour pallier ce problème, les capteurs virtuels *adaptatifs* mettent à jour les modèles avec les nouveaux échantillons [13] ou réapprennent un nouveau modèle entièrement. Des techniques d'échantillonnage sélectif ou de pondération des données peuvent être utilisées pour le réapprentissage ; des méthodes ensemblistes entraînent un nouvel apprenant faible (*weak learner*) pour chaque nouveau comportement normal [7]. Enfin, l'utilisation récente de modèles d'apprentissage profond (*deep learning*) pour la tâche de détection met en évidence un des défis de l'apprentissage incrémental : le dilemme stabilité-plasticité, qui peut conduire à un oubli catastrophique (*catastrophic forgetting*) dans certains cas (trop de plasticité) [10].

Plusieurs cadres plus généraux ont émergé dans la littérature scientifique pour décrire des applications dans lesquelles différents aspects du phénomène modélisés évoluent dans le temps (e.g. *Online, Sequential, Incremental, Lifelong, or Continual Learning* [3]). Cependant la majorité des études recensées se focalise sur des tâches de classification et des modèles d'apprentissage profond ; seules quelques études appliquent l'approche du *continual learning* à la régression [6]. Les capteurs virtuels peuvent être vu comme un cas particulier d'apprentissage incrémental au niveau du domaine des entrées (nouvelles données normales) et avec une tâche unique (régression).

Sur la base de cet état de l'art, nous pouvons distinguer trois problématiques concernant la mise à jour des capteurs virtuels :

- *Quand* mettre à jour : mise à jour périodique (jour, mois, etc...) ou déclenchée par un modèle de détection de nouveauté [14]. [6] propose l'utilisation d'un tampon (*novelty buffer*) qui accumule les données et, passé un seuil, lance une mise à jour ;
- *Quelles* données intégrer : sous-échantillonner si les données sont trop abondantes ; générer certaines données pour équilibrer la taille des classes (*boosting*) ; écarter certaines valeurs pour préserver le modèle (comportement normal) ;
- *Comment* injecter les données : réapprentissage complet d'un nouveau modèle ; mise à jour pondérée des paramètres ; nouvel apprenant faible ;

Dans la plupart des cas, la littérature se focalise sur la classification et considère que toutes les données de l'échantillon sont utilisables pour le réapprentissage. Quelques études sur les capteurs virtuels adaptatifs se penchent sur la question de *quelles* données intégrer. Elles proposent des modèles ou architecture spécifiques [14]-[15]. Cependant, leur tâche reste de la classification (normal/faute). Finalement, aucune des études recensées ne vise à évaluer différentes stratégies de réapprentissage : une seule stratégie est implémentée et ses performances ne sont pas systématiquement comparées.

A notre connaissance, il n'y a pas d'étude à ce jour qui compare systématiquement diverses approches d'apprentissage incrémental pour la régression dans le cadre des capteurs virtuels de détection de fautes (0). Les données représentant des défaillances dans les processus sont un cas extrême de valeurs aberrantes ou de dérive conceptuelle : les propriétés statistiques des données lors d'une période de faute

sont différentes de celles de l'échantillon d'entraînement. Cependant, à l'opposé des techniques habituelles gérant la dérive conceptuelle, la mise à jour du modèle devrait être protégée de ces déviations afin de pouvoir continuer à les détecter. Il s'agit donc de choisir minutieusement les données que l'on intègre au modèle afin de préserver sa fonction : modéliser le comportement normal de l'équipement.

2) Cadre général

Un modèle initial M_1 est appris sur un jeu de données initial D_1 , considéré propre : il ne contient que des données normales. Les étapes ci-dessous sont ensuite effectuées en séquence :

1. Utiliser M_1 pour prédire le comportement normal de la variable cible et détecter les fautes sur la période suivante (jeu de données D_2) ;
2. Filtrer les données D_2 en conservant uniquement des données normales (en se basant sur la détection faite à l'étape 1) pour obtenir D_2' ;
3. Mettre à jour le modèle M_1 avec D_2' afin de créer un nouveau modèle M_2 ;
4. Itérer : répéter les étapes 1-3 avec le modèle M_2 et le jeu de données D_3

La Fig. 5 ci-dessous présente cette procédure. L'étape de nettoyage (2) est indiquée par un astérisque (*).

Notons que cette procédure décrit une mise à jour « en ligne » (*online*) à l'étape 3. Celle-ci peut facilement être adaptée pour prendre en compte un réapprentissage complet, en la remplaçant par l'étape 3' suivante :

- 3'. Concaténer D_2' à D_1 , et entraîner un nouveau modèle M_2 sur ce jeu de données complet

3) Implémentation considérée

Suivant le cadre général détaillé en III.B.2, notre étude considère l'implémentation particulière suivante : une période d'entraînement de quatre semaines est utilisée pour D_1 ; le pas d'itération (l'incrément) est d'une semaine. L'étape de nettoyage (2) contient deux sous-étapes :

- *Filtrage automatique des fautes* : certaines fautes prédites par le modèle sont annulées :
 - **Niveau 1** : les données non vues auparavant (hors de l'intervalle d'entraînement) sont étiquetées « normal » ;
 - **Niveau 2** : les fautes transitoires et/ou détectées comme irréaliste par des règles expertes sont également étiquetées « normal ». La règle peut être fondée sur la physique, par exemple la situation de sous-




Fig. 5. Cadre de l'apprentissage incrémental

chauffe n'est peut-être pas une faute réelle, mais plutôt une erreur de prédiction

- *Validation des fautes* : les fautes sont présentées à un opérateur humain (expert). Ce dernier est chargé de confirmer ou infirmer les fautes (ces dernières seront réétiquetées comme « normales »).

Enfin, un nouveau modèle est complètement réentraîné sur l'ensemble des données disponibles à chaque itération (étape 3' au lieu de l'étape 3). Cela favorise l'optimalité des modèles. Les échantillons de données étant petits et les modèles considérés simples, un réapprentissage complet n'est pas rédhibitoire. La sécurité des données et le stockage de celles-ci ne sont pas non plus des enjeux pris en compte dans ces expériences. La Fig. 6 présente la procédure complète.

C Simuler pour valider

La validation de l'orchestration du VSFD présentée ci-haut (III.B.3) est rendue difficile par la rareté des données de terrain représentant des situations de faute. Nous proposons donc de simuler la procédure entière sur des jeux de données réalistes. Nous pouvons ainsi évaluer le bon comportement du capteur virtuel et choisir entre certaines alternatives algorithmiques (paramètres, configuration, ...).

1) Jeux de données annotés

Les jeux de données injectés dans le simulateur sont des mesures réelles (séries temporelles multivariées) collectées sur le terrain durant plusieurs mois d'opération. Chaque jeu est annoté avec zéro à plusieurs *périodes de faute*. Ces dernières sont définies par un horodatage de début et de fin et encadrent une défaillance observée sur le terrain. De manière générale, les horodatages sont plus larges que les périodes de faute réelles car l'hypothèse est faite que celles-ci démarrent avant qu'un opérateur humain n'ait pu les détecter. De plus, les registres de terrain peuvent être imprécis et contenir des horodatages laxistes.

2) Configurations algorithmiques

Huit configurations pour le capteur virtuel sont évaluées dans cette étude. La taille de la fenêtre glissante est fixée à : 1h, 2h, 3h, 6h, 9h, 10h, 12h, 24h. Pour chacune de ces configurations, quatre seuils alternatifs pour la détection de fautes sont testés (*fault detection threshold multiplicator*, voir [5]) : 2, 2.5, 3, 3.5.

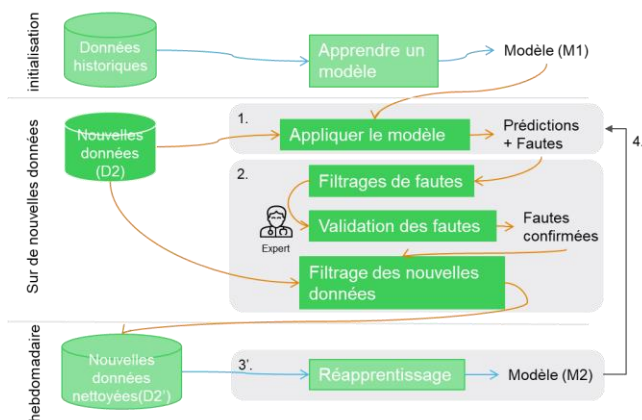


Fig. 6. Orchestration du VSFD

3) Stratégies de mise à jour

La seule réelle difficulté présente dans les étapes décrites en III.B.3) (et Fig. 6) est la simulation de l'expert humain qui arrive à l'étape 2 (*Validation des fautes*). Il peut également y avoir des erreurs au niveau de l'étiquetage des fautes (faux négatifs) lors du filtrage de niveau 2. Pour gérer ces difficultés, notre étude propose trois stratégies pour simuler le processus de filtrage des fautes et de leur validation : *conservatrice*, *réaliste* et *oracle*.

Stratégie conservatrice : l'objectif est de ne pas prendre de risques de réinjection de faute. Seul le filtrage de niveau 1 est actif ; toutes les autres fautes préservent leur statut. Le filtrage de niveau 2 est désactivé et l'expert valide toutes les fautes. Autrement dit, seules les données n'étant pas marquées comme faute par le VSFD et celles à l'intérieur du domaine des données utilisées pour la phase d'entraînement sont gardées pour le réapprentissage. Ce scénario réinjecte un volume minimal de données à chaque itération.

Stratégie réaliste : similaire à la stratégie précédente, mais cette fois-ci le filtrage de niveau 2 est également actif. Seul l'expert n'infirme pas de fautes. Cette stratégie par rapport à la conservatrice réinjecte comme « normales » les données invalides d'un point de vue physique, ou transitoires. Cette stratégie réinjecte un volume moyen de données.

Stratégie oracle : dans cette stratégie, les deux niveaux de filtrage automatique sont activés et l'expert est omniscient : il sait lorsque les fautes se produisent. Autrement dit, toutes les fautes qui ont été validées par le filtrage automatique et qui se situent en dehors des périodes de fautes, sont marquées comme « normales » et utilisées pour le réapprentissage. Dans ce scénario, un volume maximal de donnée est réinjecté.

Les stratégies conservatrice et expert ont des comportements opposés et font office de bornes de la réalité. Dans les stratégies conservatrice et réaliste, l'expert n'a pas confiance en sa capacité à reconnaître les fautes, alors que c'est l'inverse dans la stratégie experte. Dans la réalité, les experts se situent entre réaliste et oracle : ils peuvent adapter leur comportement au client ou à l'équipement surveillé, et utiliser leurs compétences pour analyser les séries temporelles et infirmer les fausses alarmes. Simuler une telle stratégie est hors du cadre de cette étude.

4) Métriques d'évaluation

Cette section introduit les métriques de performance utilisées pour évaluer la qualité d'une simulation (un couple fenêtre glissante, seuil de détection).

Chaque observation est étiquetée comme *faux positif* (FP), *vrai positif* (TP – true positive), *faux négatif* (FN) ou *vrai négatif* (TN – true negative) en fonction de la concordance des résultats des étapes de filtrage et de la vérité terrain (*ground truth*). Dans notre cas, *positif* correspond à une faute et *négatif* à une observation normale.

Un premier indicateur *Fault Detection (FD)* renseigne si au moins une alarme a été signalée durant la période de faute ; cet indicateur est donc binaire : 0 (pas de fautes) ou 1 (au moins une faute).

Un deuxième est le *Fault Period Coverage* (alias *rappel* ou *sensibilité*) ; il est défini par le ratio entre le nombre de vrais positifs et le nombre d'observations à l'intérieur de la période de faute.

TABLEAU I
DESCRIPTION DES CAS D'UTILISATION (ÉCHANTILLONNAGE DES DONNÉES AUX 15 MINUTES)

Cas	Client	Équipement	Sous-ensemble	Période de faute	Période couverte	# d'observations # d'observation
1.1	1	Panneau LV	N° 1	01/03/2019 – 15/04/2019	04/06/2018 – 08/03/2021	96,799
1.2	1	Panneau LV	N° 2	∅	04/06/2018 – 08/03/2021	96,799
2.1	2	Panneau LV	N° 1	∅	10/07/2019 – 11/03/2020	23,497
2.2	2	Panneau LV	N° 2	01/10/2019 – 31/10/2019	10/07/2019 – 11/03/2020	23,497
3.1	3	Panneau MV	N° 1	01/09/2020 – 30/09/2020	14/11/2019 – 24/03/2021	47,620

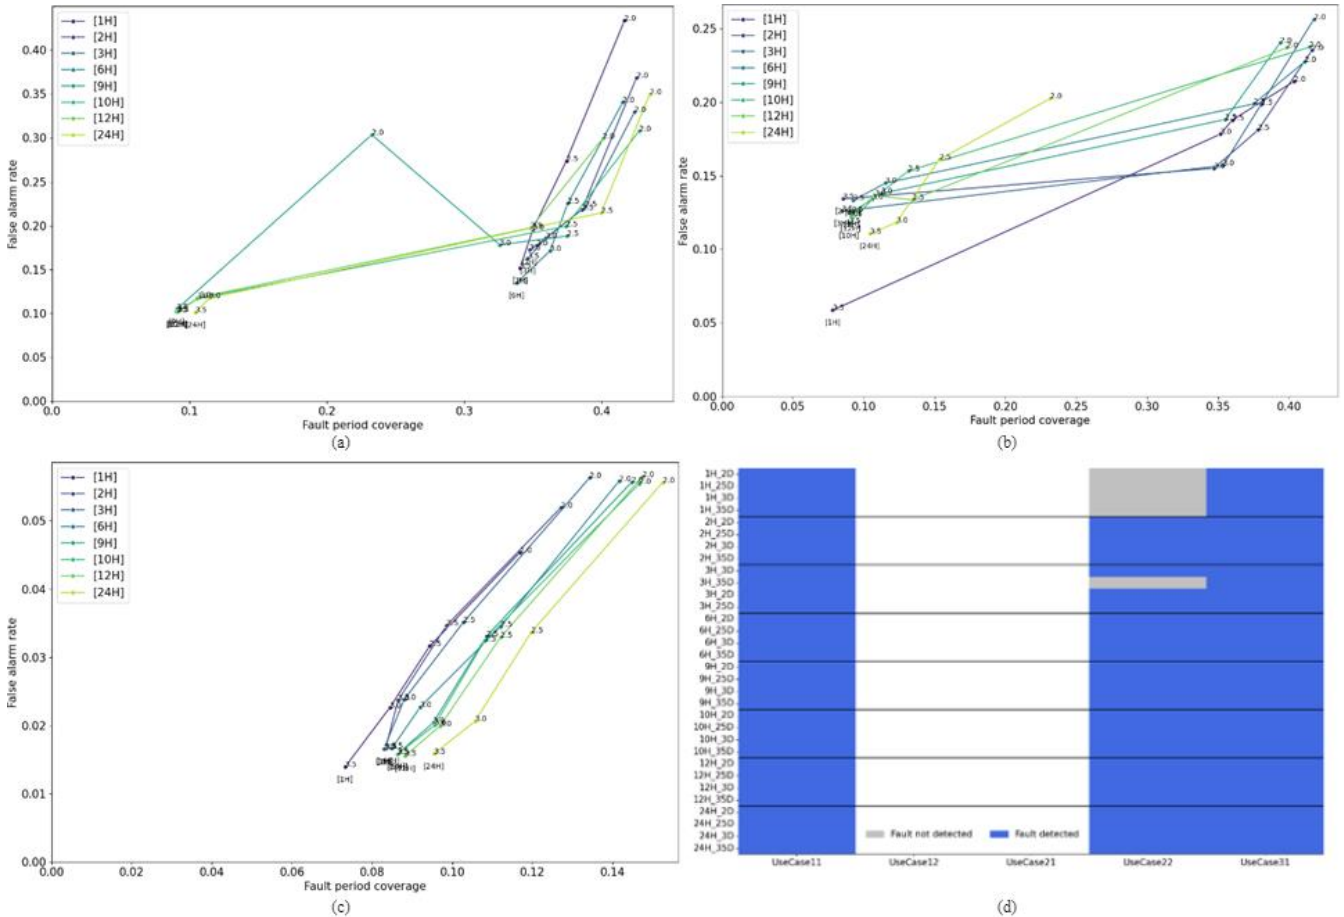


Fig. 7. Résultats pour les stratégies Conservatrice (a), Réaliste (b) et Experte (c). Carte de fréquentation des FDs (d)

Enfin, le *False Alarm Ratio (FAR, alias taux de faux positif)* est défini par le ratio entre le nombre de faux positifs et le nombre d'observations en dehors de la période de faute.

$$FPC = \frac{TP}{TP + FN} \quad FAR = \frac{FP}{FP + TN}$$

D Résultats expérimentaux

Des données provenant de trois équipements sont utilisées pour cette étude : deux tableaux basse tension et un tableau moyenne tension. Un jeu de données peut représenter des sous-composants du tableau : câble, jeu de barres ou disjoncteur débrochable. Les jeux de données peuvent s'étendre sur plusieurs mois et contenir zéro ou une période de faute annotée (qui peut être approximative, voir III.C.1). Le Tableau 1 décrit les jeux de données utilisés.

Nous avons lancé la procédure décrite en III.B.3 sur l'espace de configuration suivant : 5 cas d'utilisation, 8 fenêtres glissantes, 4 seuils de détection et 3 stratégies de mise à jour de la base des données. Pour les 480 configurations possibles, le *FD*, *FPC* et le *FAR* sont calculés puis moyennés par cas d'utilisation afin d'obtenir une seule métrique par combinaison (stratégie × fenêtre × seuil).

La Fig. 7 présente les résultats obtenus. Pour chacune des stratégies considérées (graphiques a-c), le *FPC* (abscisse) et le *FAR* (ordonnée) sont tracés pour toutes les configurations algorithmiques. Les graphiques a-b-c permettent de comparer la performance (*FPR*, *FAR*) des différentes stratégies en fonction de la configuration (fenêtre glissante, valeur de delta). Nous groupons les résultats par fenêtre glissante (un groupe par couleur) et traçons pour chaque groupe les

métriques selon le seuil de détection. Une carte de chaleur (d) illustre enfin les résultats pour le *FD* de la stratégie conservatrice (les autres stratégies ont des résultats identiques qui ne sont pas affichés ici).

La carte de chaleur nous permet d'emblée d'écarter les modèles utilisant une fenêtre temporelle d'une heure ([1H]) : peu importe le seuil de détection, aucun n'a pu détecter la période de faute sur le cas d'utilisation 2.2. Nous faisons le même constat pour la configuration [3H] avec multiplicateur de seuil 3.5.

Les nuages de points (a – c) nous renseignent sur plusieurs tendances. Tout d'abord, la quantité de fausses alarmes (*FAR*, ordonnée) diminue à travers les stratégies : conservatrice (10-44%), réaliste (5-25%) et oracle (1-6%). Cette tendance semble confirmer l'importance du retour de l'expert lors de l'apprentissage incrémental.

A propos du *fault period coverage* (*FPC*, abscisse) :

- Oracle (c) : tous les modèles ont des valeurs similaires (~10%). Ce consensus semble indiquer que la période de faute *réelle* est plus courte que celle annotée dans le jeu de données. De plus, nous observons que les fenêtres glissantes plus larges ont une meilleure couverture : elles approchent les 10% contrairement à 5% pour les fenêtres plus étroites. Pour le reste de l'analyse, nous gardons la valeur de 10% comme référence de couverture optimale ; ce qui a pour conséquence de classer les valeurs > 10% comme « fortuitement/ faussement » meilleures ;
- Réaliste (b) : nous pouvons délimiter deux groupes de modèles à valeurs similaires (gauche : ~10% comme Oracle ; droite : ~40%). Le groupe de gauche (« correct ») correspond aux valeurs de seuil de détection plus élevées, et celles plus faibles pour le groupe de droite. Avec ce scénario, les résultats semblent indiquer que tous les modèles peuvent atteindre le *FPC* de référence en augmentant simplement le seuil de détection ;
- Conservatrice (a) : on observe les mêmes groupes (même valeurs) qu'avec la stratégie Réaliste. Cependant, augmenter ici le seuil de détection ne serait pas suffisant pour décaler les modèles à fenêtre glissante étroite (< 6h) vers le groupe de gauche. Ceci nous mène à conclure que pour traiter ce scénario difficile, les fenêtres larges sont préférables. Nous remarquons également la présence d'une valeur aberrante sur cette figure.

De manière générale, ces résultats soulignent une meilleure stabilité des modèles à fenêtre glissante large (supérieure à 6 heures) et un seuil de détection élevé (3.5) ; et ce même dans la stratégie *Conservatrice*, qui représente le scénario d'apprentissage le plus difficile. L'utilisation du filtrage de niveau 2 (III.B.3) réduit nettement le déclenchement de fausse alarme et améliore la stabilité des modèles. Enfin, notons que ces résultats ont été obtenus à partir que de cinq jeux de données – dont deux sans période de faute. Il serait donc pertinent de poursuivre des études à plus grande échelle afin de corroborer ou non les tendances observées.

IV. CONCLUSIONS

La maintenance conditionnelle des équipements critiques nécessite à la fois une analyse à court et long terme afin de pouvoir à la fois détecter des anomalies et suivre la dégradation progressive du matériel. Chez Schneider Electric, nous combinons des approches par apprentissage automatique (court terme) et par modèles physiques (long terme). La validation de telles approches présente des défis. En effet, la plupart des données réelles reflète le comportement normal et ne s'étend pas sur une période suffisamment longue pour capturer la dégradation de l'équipement.

Dans cet article, nous proposons d'utiliser la simulation pour surmonter ces des difficultés :

- La simulation de la dégradation long-terme nécessite de simuler l'environnement de l'équipement et son usage pendant des décennies. La simulation des conditions environnementales (la température, l'humidité...) est effectuée en utilisant à la fois les méthodes des séries temporelles (par exemple le modèle ARIMA) et la modification des séries temporelles issues des capteurs. La simulation de l'usage est faite en utilisant des modifications des profils de charge réels, représentatif de la diversité des cas d'utilisation. Enfin, plusieurs scénarios de maintenance peuvent être simulés dans le but d'évaluer leur efficacité : pratiques actuelles sur le terrain, optimisation de la maintenance, etc.
- Concernant les approches d'apprentissage automatique (court-terme), nous pouvons utiliser des données réelles dans le simulateur puisqu'une période de quelque mois ou de quelques années est suffisante pour constater la convergence et la détection des fautes. Cependant, le défi ici provient de la simulation de l'apprentissage incrémental du modèle au cours du temps, tout particulièrement si un être humain est censé confirmer/infirmier les fautes. Nous proposons de délimiter l'espace d'exploration avec une représentation pessimiste et optimiste du de comportement humain, ainsi qu'un scénario médian « plausible ».

REFERENCES

- Chevalier, M., S. Marié, B. Boguslawski, M. Cercueil, F. Chupot, A. Vignon, and W. Youssef. 2021. "Combining First Principles and Machine Learning for optimal maintenance of electrical assets". In *CIGI QUALITA 2021*. May 2021, Grenoble, France.
- Curreri F., G. Fiumara, and M. Xibilia. 2020. "Input Selection Methods for Soft Sensor Design: A Survey". *Future Internet* vol. 12, no. 6: 97. <https://doi.org/10.3390/fi12060097>.
- Delange, M., R. Aljundi, M. Masana, S. Parisot, X. Jia, A. Leonardis, ... and T. Tuytelaars. 2021. "A continual learning survey: Defying forgetting in classification tasks". *IEEE Transactions on Pattern Analysis and Machine Intelligence*. doi: 10.1109/TPAMI.2021.3057446
- Crawley D. B. and K. L. Lawrie. 2019. "Should We Be Using Just 'Typical' Weather Data in Building Performance Simulation?". In *16th IBPSA Conference*, 2019. <https://climate.onebuilding.org>
- Gao, T., B. Boguslawski, S. Marié, P. Béguery, S. Thebault, and S. Lecoeuche. 2019. "Data mining and data-driven modelling for Air Handling Unit fault detection". In *E3S Web Conf.*, Volume 111, *CLIMA 2019 Congress*. Bucharest, Romania.
- He, Y. and B. Sick. 2021. "CLear: An adaptive continual learning framework for regression tasks". *AI Perspectives* vol. 3(1), pp. 1-16.

- Kadlec, P., R. Grbić and B. Gabrys. 2011. "Review of adaptation mechanisms for data-driven soft sensors". *Computers & chemical engineering* vol.35(1), pp. 1-24.
- Kegel, L. M. Hahmann, and W. Lehner. 2017. "Generating What-If Scenarios for Time Series Data". In *Proceedings of the 29th International Conference on Scientific and Statistical Database Management (SSDBM '17)*. Association for Computing Machinery, New York, NY, USA, Article 3, pp. 1–12.
- Masterpact MTZ Maintenance guide, 2015
<https://www.se.com/ww/en/download/document/0613IB1202/>
- Parisi, G. I., R. Kemker, J. L. Part, C. Kanan and S. Wermter. 2019. "Continual lifelong learning with neural networks: A review". *Neural Networks* vol. 113, pp. 54-71. ISSN 0893-6080
- Rizzi S. (2009) What-If Analysis. In: LIU L., ÖZSU M.T. (eds) *Encyclopedia of Database Systems*. Springer, Boston, MA. https://doi.org/10.1007/978-0-387-39940-9_466
- Schneider Electric, 2021, <https://www.se.com/ww/en/work/services/service-plan/ecostruxure-service-plan.jsp>
- Souza, F. A., R. Araújo and J. Mendes. 2016. "Review of soft sensor methods for regression applications". *Chemometrics and Intelligent Laboratory Systems* vol. 152, pp. 69-79.
- Carino, J. A., et al. 2018. "Fault Detection and Identification Methodology Under an Incremental Learning Framework Applied to Industrial Machinery," in *IEEE Access*, vol. 6, pp. 49755-49766.
- Yu, Y., Peng, M., Wang, H., Ma, Z., Cheng, S., & Renyi, X. 2021. "A continuous learning monitoring strategy for multi-condition of nuclear power plant". *Annals of Nuclear Energy*, 164, 108544.