



HAL
open science

Couplage de jumeau numérique et réseau de neurones pour la détection et l'analyse des micro-pannes dans un système de production

Farah Abdoune, Maroua Nouri, Olivier Cardin, Pierre Castagna

► To cite this version:

Farah Abdoune, Maroua Nouri, Olivier Cardin, Pierre Castagna. Couplage de jumeau numérique et réseau de neurones pour la détection et l'analyse des micro-pannes dans un système de production. 17ème colloque national S-mart AIP-PRIMECA, Université Polytechnique Hauts-de-France [UPHF], Mar 2021, LAVAL VIRTUAL WORLD, France. hal-03296113

HAL Id: hal-03296113

<https://hal.science/hal-03296113>

Submitted on 22 Jul 2021

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.

Couplage de jumeau numérique et réseau de neurones pour la détection et l'analyse des micro-pannes dans un système de production

Farah ABDOUNE , Maroua NOURI , Olivier CARDIN, Pierre CASTAGNA

LS2N, UMR CNRS 6004, Université de Nantes, IUT de Nantes, 44 470 Carquefou, France

Farah.Abdoune@univ-nantes.fr; Maroua.Nouiri@univ-nantes.fr ;
Olivier.Cardin@univ-nantes.fr; Pierre.Castagna@univ-nantes.fr

Résumé— À l'ère de l'industrie 4.0, le jumeau numérique apparaît comme un paradigme qui joue un rôle clé dans l'amélioration de l'efficacité globale des équipements (OEE). Parmi les six grandes pertes d'efficacité mesurées dans le cadre de la maintenance productive totale, le Digital Twin peut augmenter la disponibilité du système de production en effectuant une maintenance prédictive ou peut se concentrer sur les pertes de performances qui représentent une partie importante des pertes de production quotidiennes. Ce travail vise à améliorer les performances des systèmes de production en exploitant les fonctionnalités du jumeau numérique et en utilisant un réseau de neurones pour repérer et analyser les micro-défaillances.

Mots-clés— Jumeau numérique, Machine Learning, système de production, micro-pannes, Réseau de neurones.

I. INTRODUCTION

Avec la 4ème révolution industrielle, les entreprises se doivent de rester compétitives, et pour cela l'optimisation des gains en mettant en œuvre des indicateurs clés de performance puissants peut se révéler un atout important pour la prise de décision. Dans ce contexte, l'évolution des systèmes de production cyber-physiques exige qu'ils soient capables de s'adapter et de réagir au mieux aux aléas de production et aux pertes de performances. La maintenance productive totale (TPM) est une méthodologie permettant de maintenir et améliorer la performance des équipements dans le secteur de l'industrie développées par Nakajima [1]. Dans cette méthodologie, le taux de rendement global (TRG) permet de mesurer l'efficacité des systèmes de production, afin d'identifier les pertes et les différents aléas de production. Le calcul du TRG permet aux industriels d'identifier les principales pertes et prendre les décisions nécessaires afin d'y remédier. Le TRG est défini par la formule suivante :

$$\text{TRG} = \text{Disponibilité} \times \text{Performance} \times \text{Qualité} \quad (1)$$

où le taux de disponibilité est le rapport entre le temps brut de fonctionnement et le temps de production prévu, le taux de performance est le rapport entre le temps de cycle réel et le temps de cycle idéal et le taux de qualité est le rapport entre le nombre de bons produits et le nombre total de produits fabriqués [2]. Ces trois paramètres sont souvent influencés par les six grandes

sources de pertes : (i) Pertes de rendement dues aux pannes d'équipement ; (ii) Pertes dues aux configurations et aux ajustements ; (iii) Pertes dues à la marche à vide et aux arrêts mineurs ; (iv) Pertes de vitesse de fonctionnement due à des cadences de fonctionnement réduites ; (v) Pertes dues aux défauts de qualité et aux retouches et (vi) Pertes liées au démarrage d'équipements[3].

Au sein de ces causes, les arrêts mineurs, aussi appelés micro-arrêts, micro-défaillances ou micro-pannes sont très difficiles à évaluer de par leur hétérogénéité et leur fréquence d'apparition très variable. Il a été démontré dans une étude [4] que près de 90% des pertes sont dues aux arrêts sont les pertes de vitesses, les micro arrêts et les pannes.

Ces micro-défaillances signifient que la machine s'arrête, pendant un temps court et fréquent, à cause d'un évènement mineur. Dans de nombreux cas, elles ne sont pour ainsi dire pas prises en compte, même si elles peuvent être chroniques. Au total, elles peuvent ainsi représenter une part importante des pertes de disponibilité et de performance d'un équipement.

Ce papier a pour objectif de proposer un nouvel outil permettant à la fois de suivre et repérer les différentes micro-défaillances au travers d'un jumeau numérique, pour ensuite les classifier grâce à un outil de Machine Learning. Pour cela, nous nous basons sur l'implémentation du jumeau numérique afin de modéliser l'état d'un système de production, anticiper ses performances nominales, faciliter l'accès aux données, et ainsi donner la possibilité de détecter tout écart de fonctionnement entre le réel et le nominal. Un réseau de neurones a été développé, permettant d'exploiter les données issues du jumeau numérique pour en extraire les informations utiles concernant les pertes de performance et les micro-défaillances. Une étude de cas est proposée sur une ligne d'assemblage automatisée S.mart de l'IUT de Nantes.

La section suivante présente un ensemble de travaux relatifs à la problématique de perte de performance et d'efficacité dans les systèmes de production. Ensuite, les concepts de jumeau numérique et de Machine Learning sont présentés, avant la définition de l'architecture de couplage entre ces deux outils.

Enfin, l'étude de cas est présentée et démontre la possibilité d'identifier automatiquement un ensemble de micro-défaillances sur notre cas d'application

II. ETAT DE L'ART :

Les articles recensés qui portent à la fois sur le jumeau numérique et les micro-défaillances sont rarissimes. De ce fait, nous nous intéressons dans cette revue de littérature aux travaux menés sur les pertes de performance et d'efficacité des systèmes de production, ainsi que les méthodes employées pour y remédier.

Pour évaluer et mettre en évidence l'impact de la survenance de certains événements comme l'endommagement des outils de production ou la variabilité des opérations humaines sur les performances d'une chaîne de montage automobile, une approche de simulation à événements discrets est souvent employée[5] afin de simuler par exemple les pertes dues à la fatigue, au climat, à l'environnements et aux micro-défaillances. En analysant les résultats de simulation, il a été démontré qu'il est possible d'évaluer de manière préventive ou en temps quasi réel, le TRG.

Certains auteurs penchent vers des modèles mathématiques afin de démontrer l'influence de certains facteurs sur la performance. Afin d'étudier la relation entre les facteurs technologiques, humains et produits et les pertes de vitesse [6], une régression généralisée des moindres carrés est ainsi appliquée sur deux lignes de production. Suivant la même approche, des modèles géométriques et stochastiques sont proposés pour optimiser et analyser les pertes de performances des machines de production complexes[7].

D'autres travaux suggèrent des méthodes d'intelligence artificielle pour prédire certaines valeurs liées au TRG. Des méthodes de lissage sont utilisées dans R studio en vue de prédire les performances futures du TRG [8], utilisant un algorithme d'apprentissage supervisé pour une technique de prévision en utilisant les données historiques de l'OEE, tandis qu'un autre algorithme est développé pour prendre en compte toute tendance actuelle en utilisant l'apprentissage non supervisé en se basant sur les pertes de disponibilité, de performance et de qualité [9]. Différents algorithmes d'apprentissage automatique que sont la machine à vecteurs de support, Random Forest, XGBoost et Deep Learning ont été expérimentés pour prédire les valeurs du TRG estimées d'une industrie de production de câbles automobile afin d'identifier et éliminer les pertes relatives à la performance. Des méthodes empiriques et analytiques ont également été exploitées pour l'identification des causes de pertes, l'amélioration de performance et la réduction des temps de cycle.

D'autre part, différents auteurs ont employés des méthodes analytiques et empiriques. A partir d'une analyse des six principales causes de pertes, il a été démontré via une analyse de Pareto que près de 90% des pertes dues aux arrêts sont les pertes de vitesses, les micro-arrêts et les pannes [4]. En industrie des semi-conducteurs, l'identification et quantification des catégories de perte de vitesse, ainsi que la mise en place d'actions spécifiques ciblées sur les pertes de vitesse au niveau d'un

ensemble d'outils, a permis d'avoir un impact direct sur la capacité globale et les performances de l'usine [10].

Dans un même ordre d'idée, les auteurs implémentent la maintenance productive totale (TPM) dans l'industrie alimentaire en utilisant une méthodologie de développement en quatre étapes afin d'éliminer les pertes de performance et de qualité [11]. La méthodologie est basée sur l'analyse des données de fiabilité d'une ligne de production automatique, dont l'objectif est d'améliorer la politique de maintenance. L'approche DMAIC a été utilisée pour définir, mesurer, analyser, améliorer et contrôler systématiquement les performances de l'équipement[12]. Le but est de discuter et de mettre en évidence la méthodologie six-sigma pour réduire le goulot d'étranglement et le temps de cycle et en l'occurrence éliminer les pertes de temps dans le processus de production. Entre autres, une industrie du tabac faisait face à un problème en raison de pannes, défauts d'équipement et mauvais fonctionnement. L'objectif est de réduire les pertes de temps en implémentant la maintenance productive et en utilisant la méthode AMDEC (analyse des modes de défaillance, de leurs effets et leurs criticité). Après la mise en œuvre, le taux de performance est passé de 75% à 79% [13].

Selon nos recherches, peu de travaux ont finalement étudié les pertes de performances liées aux micro-défaillances, ce qui implique se priver d'un levier permettant une meilleure efficacité du système de production.

III. JUMEAU NUMERIQUE

Le concept du jumeau numérique (Digital Twin - DT) a été proposé pour la première fois par le professeur Grieves de l'Université du Michigan dans le cadre de la gestion du cycle de vie des produits [14]. Il est désormais attendu qu'un DT ait la capacité d'augmenter l'intelligence et les performances d'un système de production cyber-physique (CPPS) grâce à des fonctions d'analyse, de prédiction, de diagnostic et d'optimisation des performances [15]. Au cours des dernières années, il a été proposé d'utiliser le paradigme du jumeau numérique pour réduire ou éliminer les risques potentiels sur les actifs et améliorer l'efficacité, la maintenance et la disponibilité des systèmes de production [16].

La définition générale d'un jumeau numérique reste à nos jours mitigée, les industriels et les chercheurs le définissant de plusieurs manières. Glaessgen et Stargel [17] proposent la définition la plus courante d'un jumeau numérique : « une simulation multi-physique, multi-échelles et intégrée d'un produit complexe et utilise les meilleurs modèles physiques disponibles, mises à jour par les capteurs pour refléter la vie de son jumeau correspondant ». Bien que la terminologie ait évoluée au fil des ans, le concept d'un jumeau numérique est généralement basé sur le monde réel, récupérant en temps réel des données, nous permettant de visualiser l'évolution de système ou du processus dans le monde numérique et de fournir des informations sur la performance de celui-ci.

Une des définitions initiales des jumeaux numériques a énuméré trois fonctions principales de jumeau numérique [18], [19] : la surveillance, la prédiction et le diagnostic. Ces fonctionnalités consistent à étudier le comportement du système

réel avant, durant ou après la survenance d'évènements spécifiques respectivement. Au travers de ces trois fonctions, il doit être possible de prédire le comportement du système face à un événement inattendu, après, pendant, voire avant qu'il ne se produise[20].

Ces types de prédictions sont réalisés en analysant la réponse actuelle du système et le comportement nominal prévu. Un jumeau numérique nécessite donc d'être pourvu de moyens de collecte et d'échange de données, ainsi que de modèles de comportement.

IV. MACHINE LEARNING

L'utilisation d'algorithmes d'intelligence artificielle a permis de faire un grand pas en avant dans le contrôle et la surveillance des processus industriels [21]. La mise en œuvre d'algorithmes d'apprentissage automatique peut aider à prédire, optimiser, diagnostiquer et planifier le processus de production de nombreuses façons pour améliorer l'efficacité globale du système industriel.

L'apprentissage automatique est une branche de l'IA basée sur l'utilisation de données et des probabilités statistiques pour apprendre automatiquement et identifier des modèles récurrents sans programmation explicite. Il peut être subdivisé en deux catégories principales. L'apprentissage supervisé est basé sur des données historiques disponibles et étiquetées préalablement. Dans ce cadre, deux approches sont possibles : la classification et la régression [22]. La classification est le processus de recherche de modèles mathématiques et statistiques pour séparer les données en plusieurs classes, alors que la régression a pour but de distinguer les données en valeurs réelles continues. L'apprentissage non supervisé utilise des données non étiquetées, de sorte que l'algorithme d'apprentissage trouve tout seul à déterminer les critères les plus pertinents pour regrouper les données [23].

Dans cette étude, nous nous intéressons à l'apprentissage automatique supervisé afin de faire de la classification des micro-défaillances à partir de données étiquetées.

V. ARCHITECTURE PROPOSEE :

L'objectif principal de cette architecture est d'implémenter un outil apte à identifier et localiser les dysfonctionnements afin d'informer l'opérateur des arrêts potentiels qui peuvent compromettre la fiabilité et les performances du système.

L'architecture met l'accent sur la surveillance et la prédiction des micro défaillances. Le DT permet de suivre les événements survenant dans le système réel en temps réel et faire la différence avec le comportement nominal. Cela permet de détecter les perturbations et les enregistrer dans une base de données. Le traitement des données à l'aide d'un algorithme d'apprentissage automatique pour classer les dysfonctionnements enregistrés et les prédire, assure la seconde fonctionnalité.

L'architecture proposée est composée de deux couches : cyber et physique. Celles-ci sont à leur tour divisées en quatre modules : l'espace réel, l'espace virtuel, le module intelligent et le centre de décision (voir Figure 1). Cette architecture

intègre les architectures proposées récemment dans la littérature par Tao [24], qui affirme qu'un cadre préliminaire générique du DT doit comporter au moins cinq parties: espace physique, espace virtuel, la connexion entre les deux, les données et le service.

1. Système physique :

La couche physique se réfère principalement au système de production comprenant la ligne de production et ses postes de travail, le stockage, les moyens de transfert, les capteurs, les actionneurs, les contrôleurs, le système d'exécution de fabrication, etc. Cette couche est chargée de fournir à la couche supérieure du modèle les données nécessaires.

2. Système virtuel :

Les données sont collectées en temps réel à partir de l'espace physique à l'aide d'un protocole de communication (OPC, TCP/IP, Modbus/TCP ...etc.) . Cette fonction est importante car elle permet de connaître l'état et le comportement du système réel. Les automates programmables industriels peuvent faire référence à des données mesurables concernant un produit en cours de traitement, mais également les données de capteurs et d'actionneurs nécessaires au contrôle. Ces données alimentent le modèle virtuel représentant le modèle physique. Ce modèle peut être un modèle de données (des schémas aux représentations statistiques), modèle de simulation (continu, discret, hybride...), modèles 3D, ...etc.

Ce modèle doit être en mesure de connaître l'état et le comportement du système réel et faire la différence avec le comportement nominal, pour repérer tout dysfonctionnement. Celui-ci doit également être parfaitement synchronisé avec le modèle réel pour éviter tout écart ou erreur. Les données sont stockées dans la base de données, créant ainsi un historique de comment l'équipement a été utilisé et exploité au fil du temps.

3. Module intelligent

Les données enregistrées sont ensuite nettoyées, étiquetées et transformées. Elles sont ensuite traitées à l'aide d'un algorithme de Machine Learning permettant d'extraire les informations importantes. Nous verrons cette partie plus en détails ultérieurement.

4. Centre de décision

Les résultats des analyses et l'extraction de connaissance à partir des données sont envoyées à l'opérateur. Ce dernier peut les visualiser sur une interface homme machine (IHM) dédiée connectée au système de production (e.g. une application de suivi sur son smartphone, sur objets connectés ,etc.). Ainsi, il est informé sur les dysfonctionnements éventuels et peut ainsi prendre plus rapidement la décision d'agir.

VI. DESCRIPTION DE L'ETUDE DE CAS

Afin de démontrer l'efficacité de l'architecture proposée figure 1, une étude de cas est réalisée sur la ligne d'assemblage S.mart de l'IUT de Nantes, comprenant six postes de travail différents et un magasin de stockage. La figure 2 illustre les détails d'implémentation de notre modèle dans l'étude de cas testée.

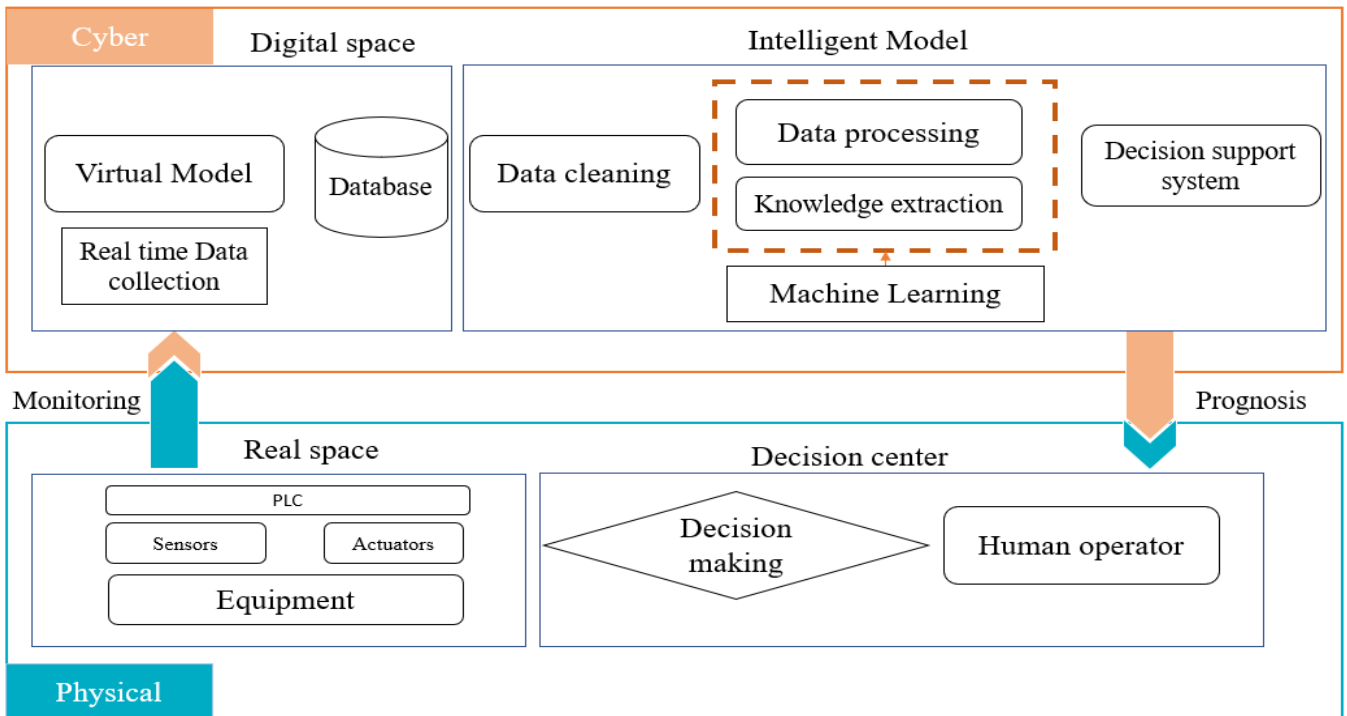


Figure 1. ARCHITECTURE D'IMPLEMENTATION

1) *Identification des micro-défaillances :*

Dans notre cas, nous avons identifié 3 principales micro-défaillances récurrentes impactant le bon fonctionnement de la ligne d'assemblage :

- Réglages incorrects d'un poste de travail
- Micro-blocages des palettes dans les virages
- Butées bloquées

2) *Récupération et Synchronisation des données :*

Un modèle de simulation (1) de la Figure 3 a été développé pour remplacer la ligne d'assemblage réelle (1) de la Figure 2 lors de la phase d'entraînement du réseau de neurones. Nous nous sommes servis de ce modèle pour générer des données qu'il nous aurait été difficile d'observer réellement sur le système réel en maîtrisant parfaitement les scénarios de défaillance générés. Il est impératif de synchroniser ce modèle avec le système réel (1) de la figure 2 pour éviter les écarts entre le modèle réel et simulé.

Nous avons ensuite créé un modèle virtuel sous Flexsim, noté (2) dans la figure 2. Le comportement de celui-ci est nominal, et il est capable de faire la différence (4) avec le comportement réel généré par le système physique (1). Le résultat de cette différence nous renseigne sur la micro-défaillance survenue, son type, l'endroit où elle s'est produite et le temps d'arrêt du système.

Les données de ces différences sont enregistrées dans une base de données MySQL ((5) de la figure 2), permettant d'avoir un historique indiquant un comportement anormal des différentes micro-défaillances ainsi que leurs caractéristiques, mais également des données représentant un comportement sain et normal.




Figure 2. ETUDE DE CAS




Figure 3. SYNCHRONISATION ET REGLAGE

3) Enregistrement, traitement et exploitation des données

Les anomalies, comme les micro-défaillances dans notre cas, peuvent être identifiées au moyen de méthodes de classification telles que les réseaux de neurones, les machines à vecteurs de support où les forêts d'arbre aléatoire.

Un réseau de neurones artificiel (RNA) a été implémenté sous python pour classifier les micro-pannes ((6) de la figure 2). Avant la phase de classification, un processus de préparation des données est nécessaire. Il comprend la sélection des données appropriées à partir des données brutes, le prétraitement des données en nettoyant ou corrigeant les données manquantes, puis la transformation des données dans une forme structurée adaptée pour travailler avec.

Ayant simulé plusieurs types de pannes relatives 3 micro-défaillances identifiées, nous avons ainsi utilisé la classification en classes multiples permettant de calculer la probabilité de défaillance due à l'une des multiples causes de micro-pannes. Quatre classes ont été ciblées dans cette étude :

- Classe 1 : avec micro-panne relative au poste de travail (machine)
- Classe 2 : micro-panne relative au blocage des palettes dans le virage
- Classe 3 : micro-panne relative au blocage dans l'aiguillage.

Les RNA sont l'un des algorithmes de ML les plus courants et appliqués, et ils ont été proposés dans de nombreuses applications industrielles [25]. Le comportement intelligent des RNA provient des interactions entre les unités de traitement du réseau. Un RNA est composé de plusieurs unités de traitement appelées neurones qui ont un fonctionnement relativement simple. Ces unités sont généralement connectées par des canaux de communication qui ont un poids associé; et ils exploitent uniquement leurs données locales qui sont indiquées par leurs connexions.

4) Exécution et résultats

Notre réseau de neurones est implémenté en utilisant une couche d'entrée de 8 neurones. Deux couches cachées sont constituées de 20 et 25 neurones respectivement. La fonction Softmax qui attribue des probabilités décimales à chaque classe d'un problème à plusieurs classes est utilisée dans la couche de sortie, cette dernière se composant de 3 nœuds.

L'architecture de notre RN utilisée dans cette section est formée par les structures et paramètres suivants : Numéro d'époque : 200 ; taille du lot= 16 ; Fonction d'activation : Algorithme d'optimisation d'Adam ; Fonction de perte : précision.

Nous séparons l'ensemble des données en deux, nous nous servons de la première partie (80 % des données) afin d'entraîner notre modèle et de la deuxième (20% des données) afin de tester sa précision et son efficacité. Nous prenons 20% des données d'entraînement pour faire la validation ultérieurement. Notre modèle a été implémenté en utilisant python 3.6 et ses différentes bibliothèques.

Nous avons obtenu une précision de 97,56 % dans notre étude de cas. Nous pouvons visualiser les résultats détaillés dans la matrice de confusion de la figure 4. Cette efficacité s'avère être

intéressante pour ce modèle. Les chiffres en diagonales représentent les instances prédites correctement.




Figure 4. MATRICE DE CONFUSION

VII. CONCLUSION ET PERSPECTIVE

Nous avons proposé une architecture afin d'implémenter dans les systèmes de production un jumeau numérique apte à améliorer la performance des systèmes de production en détectant les micro-défaillances et en les analysant avec un réseau de neurones. Cette architecture repose principalement sur la synchronisation entre le système réel et le système virtuel, l'analyse des données et les techniques d'intelligence artificielle.

Les travaux de cet article forment un socle qui ouvre des perspectives intéressantes, à plus ou moins long terme. Les tests sur la ligne d'assemblage réelle sont les premiers objectifs des travaux futurs. L'implémentation d'une interface pour la visualisation des données par l'opérateur en temps réel, l'utilisation des capteurs IoT liés à la ligne ou des objets connectés à l'opérateur afin de le prévenir des dysfonctionnements sont des possibilités envisageables afin d'améliorer l'architecture proposée. Enrichir les données pour obtenir une meilleure précision du réseau de neurones est aussi primordial.

VIII. REFERENCES

- [1] S. Nakajima, *Introduction to TPM : Total Productive Maintenance*, Productivity Press. Cambridge, 1988.
- [2] R. C. Hansen, *Overall Equipment Effectiveness: A Powerful Production/maintenance Tool for Increased Profits*. Industrial Press Inc., 2001.
- [3] P. Muchiri et L. Pintelon, « Performance measurement using overall equipment effectiveness (OEE): literature review and practical application discussion », *Int. J. Prod. Res.*, vol. 46, n° 13, p. 3517-3535, juill. 2008, doi: 10.1080/00207540601142645.
- [4] J. Hossen, N. Ahmad, et S. M. Ali, « An application of Pareto analysis and cause-and-effect diagram (CED) to examine stoppage losses: a textile case from Bangladesh », *J. Text. Inst.*, vol. 108, n° 11, p. 2013-2020, nov. 2017.
- [5] M. Caterino *et al.*, « Simulation Techniques for production lines performance control », *Procedia Manuf.*, p. 6, 2019.

- [6] A. Trattner, L. Hvam, et A. Haug, « Why slow down? Factors affecting speed loss in process manufacturing », *Int. J. Adv. Manuf. Technol.*, vol. 106, n° 5-6, p. 2021-2034, janv. 2020.
- [7] W. Nüßer et T. Steckel, « A mathematical model for the determination of performance losses of machines », *Appl. Math. Model.*, vol. 92, p. 612-623, avr. 2021.
- [8] C. Anusha et V. Umasankar, « Performance Prediction through OEE-Model », *Int. J. Ind. Eng. Manag.*, n° 2, p. 93-104, juin 2020.
- [9] I. Hassani, C. Mazgualdi, et T. Masrour, *Artificial Intelligence and Machine Learning to Predict and Improve Efficiency in Manufacturing Industry*. 2019.
- [10] J. Foster, J. Matthews, P. Beaumont, T. Zarbock, et D. Yeo, « Equipment Throughput Optimization by Means of Speed Loss Analysis », *IEEE Trans. Semicond. Manuf.*, vol. 21, n° 3, p. 371-375, août 2008.
- [11] P. Tsarouhas, « Total productive maintenance in food industry », *Food Ind.*, p. 14.
- [12] K. C. Ng, K. E. Chong, et G. G. G. Goh, « Improving Overall Equipment Effectiveness (OEE) through the six-sigma methodology in a semiconductor firm: A case study », in *2014 IEEE International Conference on Industrial Engineering and Engineering Management*, Selangor Darul Ehsan, Malaysia, déc. 2014, p. 833-837.
- [13] K. Krachangchan et N. Thawesaengskulthai, « Loss time reduction for improve Overall Equipment Effectiveness (OEE) », in *2018 5th International Conference on Industrial Engineering and Applications (ICIEA)*, Singapore, avr. 2018, p. 396-400.
- [14] M. W. Grieves, « Virtually Indistinguishable », in *Product Lifecycle Management. Towards Knowledge-Rich Enterprises*, Berlin, Heidelberg, 2012, p. 226-242.
- [15] F. Tao, J. Cheng, Q. Qi, M. Zhang, H. Zhang, et F. Sui, « Digital twin-driven product design, manufacturing and service with big data », *Int. J. Adv. Manuf. Technol.*, vol. 94, n° 9, p. 3563-3576, févr. 2018.
- [16] J. Hlady, M. Glanzer, et L. Fugate, « Automated Creation of the Pipeline Digital Twin During Construction: Improvement to Construction Quality and Pipeline Integrity », présenté à 2018 12th International Pipeline Conference, nov. 2018.
- [17] E. Glaessgen et D. Stargel, « The digital twin paradigm for future NASA and U.S. air force vehicles », avr. 2012.
- [18] M. Glatt, C. Sinnwell, L. Yi, S. Donohoe, B. Ravani, et J. C. Aurich, « Modeling and implementation of a digital twin of material flows based on physics simulation », *J. Manuf. Syst.*, mai 2020.
- [19] M. Shafto *et al.*, « Modeling, simulation, information technology & processing roadmap », *Natl. Aeronaut. Space Adm.*, 2012.
- [20] B. Schleich, N. Anwer, L. Mathieu, et S. Wartzack, « Shaping the digital twin for design and production engineering », *CIRP Ann.*, vol. 66, n° 1, p. 141-144, janv. 2017.
- [21] F. Bonada, L. Echeverria, X. Domingo, et G. Anzaldi, « AI for Improving the Overall Equipment Efficiency in Manufacturing Industry », in *New Trends in the Use of Artificial Intelligence for the Industry 4.0*, L. Romeral Martínez, R. A. Osornio Rios, et M. Delgado Prieto, Éd. IntechOpen, 2020.
- [22] S. Ray, « A Quick Review of Machine Learning Algorithms », in *2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing*, févr. 2019, p. 35-39.
- [23] A. Dey, « Machine Learning Algorithms: A Review », *Int. J. Comput. Sci. Inf. Technol.*, vol. 7, p. 6, 2016.
- [24] F. Tao *et al.*, « Digital Twin and Its Potential Application Exploration 数字孪生及其应用探索 », *Comput. Integr. Manuf. Syst.*, vol. 24, janv. 2018.
- [25] T. P. Carvalho, « A systematic literature review of machine learning methods applied to predictive maintenance », *Ind. Eng.*, p. 10, 2019.