

CIGI QUALITA MOSIM 2023

Application d'un réseau de neurones artificiels auto-encodeur pour la détection de bourrages sur tapis convoyeurs en centre de tri de déchets

CALLIANE YOU, OLIVIER ADROT, JEAN-MARIE FLAUS

Univ. Grenoble Alpes, CNRS, Grenoble INP*, G-SCOP,
38000 Grenoble, France

* Institute of Engineering Univ. Grenoble Alpes

calliane.you@gscop.fr; olivier.adrot@gscop.fr; jeanmarie.flaus@gscop.grenobleinp.fr

Résumé – En France, les déchets ménagers sont collectés et triés dans des centres de tri de déchets de collecte sélective. De 2005 à 2017, la quantité de déchets recyclables a augmenté de 35%. D'ici à 2026, l'Organisation de coopération et de développement économiques (OCDE) a estimé que dans le monde la quantité de déchets plastiques aura triplée. Et, seul moins d'un cinquième sera recyclé et la moitié ira à la décharge. Les centres de tri rencontrent un problème majeur et persistant au tri des déchets ménagers non résolu, les bourrages des tapis convoyeurs. Le flux de déchets entrant est de composition et consistance variable (matière, formes, humidité, enchevêtrement des déchets ...) entraînant des bourrages non négligeables. Détecter de potentiels bourrages est donc nécessaire. Un réseau de neurones artificiels auto-encodeur est testé dans le but de détecter de potentiels bourrages sur tapis convoyeurs en centre de tri de déchets. La méthode et les résultats sur des données réelles sont détaillés.

Abstract – In France, household waste is collected and sorted in waste sorting centers for selective waste collection. From 2005 to 2017, the amount of recyclable waste increased by 35%. By 2026, the Organization for Economic Co-operation and Development (OECD) has estimated that the amount of plastic waste worldwide will have tripled. And, only less than a fifth will be recycled and half will go to landfill. Sorting centers encounter a major and persistent problem in the sorting of household waste that has not been solved, conveyor belts jamming. The incoming waste flow is of variable composition and consistency (material, shapes, humidity, entanglement of waste, etc.) resulting in significant jams. Detecting potential jams is therefore necessary. An autoencoder artificial neural network is tested to detect potential jams on conveyor belts in waste sorting centers. The method and the results on real data are detailed.

Mots clés – Détection de défauts, Surveillance intelligente des procédés, Intelligence artificielle, Application à la détection de bourrages, Tri de déchets.

Keywords – Fault detection, Intelligent process monitoring, Artificial intelligence, Application to jam detection, Waste sorting.

1 INTRODUCTION

De 2005 à 2017, la quantité de déchets recyclables ménagers a augmenté de 35% [Ademe, 2020]. D'ici à 2026, l'Organisation de coopération et de développement économiques (OCDE) a estimé que dans le monde la quantité de déchets plastiques des consommateurs aura triplée. Et, seul moins d'un cinquième sera recyclé et la moitié ira à la décharge [OECD, 2022]. De plus, certaines politiques régionales françaises décident d'atteindre zéro enfouissement d'ici 2030 [La Région Auvergne-Rhône-Alpes, 2022]. Il est donc crucial d'optimiser le recyclage de nos déchets et ainsi de limiter les déchets non triés. Ces déchets non triés découlent de plusieurs contraintes. Il y a la contrainte de l'augmentation de la quantité de déchets à trier, et la contrainte de temps dû à la capacité initiale de tri des centres de tri qui est elle-même limitée lors de sa construction (le terrain est limité et imposé par la ville). Et il existe aussi des mesures d'hygiène et de sécurité importantes, car avec le temps l'urbanisation rapproche les habitations, et les centres de tri doivent traiter un maximum de tonnage pour limiter le stock de déchets à traiter

et donc éviter le développement des rats, de la pourriture, des odeurs, et des maladies. A cela s'ajoute la contrainte des restrictions budgétaires, territoriale et de délai qui font qu'il n'est pas toujours possible d'agrandir ou de construire d'autres centres de tri (Figure 1) pour répondre à cette augmentation du volume de déchets à trier.



Figure 1. Centre de tri de déchets ménagers

De plus, ces déchets non triés sont envoyés soit en décharge, soit en incinération, ce qui rajoute des coûts financiers et humains, ainsi que de la pollution.

Cet article de recherche se focalise sur le segment des déchets ménagers, un segment difficile dans le tri des déchets dû à ses spécificités. Le flux de déchets entrant dépend des habitudes de consommations des habitants et de la météo, ainsi que de leur manière de trier. Ce flux est donc de composition et consistance très variable (matière, formes, humidité, enchevêtrement des déchets ...) entraînant des bourrages non négligeables.

En plus de traiter un flux entrant complexe (Figure 2), le rôle des centres de tri est de maximiser la quantité de déchets triés récupérés en sorties finales de la ligne de tri c'est-à-dire les matières recyclables, et ainsi limiter la quantité de déchets refusés c'est-à-dire les refus qui s'ajoutent au tas à incinérer ou à enfouir.

Le flux de déchets entre par les machines pointées par les grandes flèches noires, et sort en plusieurs flux distincts par types de déchets triés par les machines précédentes les grandes flèches en bleues. Chaque flèche fine grise montre le sens de circulation des flux de déchets. Le logo humain représente les zones où les opérateurs trient manuellement en position debout. Un cercle représente une machine, chaque machine est physiquement différente et traite un flux de déchets différent. En rouge, la machine 1 qui sert à l'entraînement de l'algorithme et aux tests, et en vert et violet les machines 2 et 3 qui servent seulement lors des tests, elles seront détaillées dans les sections suivantes. Ces centres de tri de déchets ménagers ont donc différentes machines (robots, trieurs optiques, cribles...) et tapis convoyeurs avec de multiples boucles de recirculation qui complexifient et augmentent le risque de bourrage.

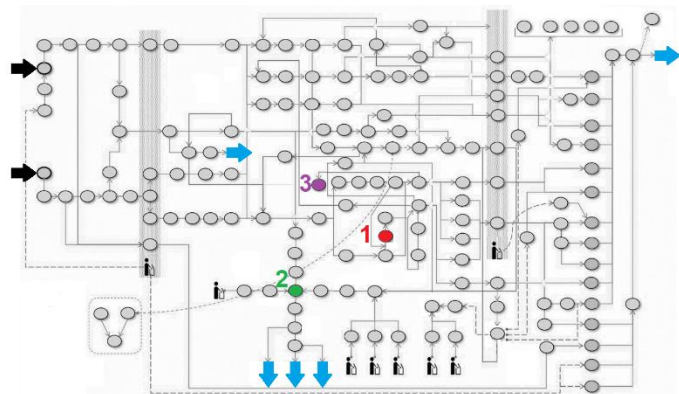


Figure 2. Exemple de l'implantation des machines d'un centre de tri de déchets ménagers

Un bourrage se produit par une accumulation de déchets, qui oblige le moteur de la machine à forcer et les opérateurs de production à arrêter la chaîne de production. Sur la figure 3, le tapis convoyeur supérieur continue de déverser des déchets alors qu'un bourrage se forme dans le tapis convoyeur suivant dans l'encadré rouge. Celui-ci déborde et déverse à son tour des déchets dans les machines situées en dessous, des blocages successifs se déclenchent sur les machines en dessous qui ne sont pas forcément successives dans le processus de tri. Ces déchets sont coincés et sont uniquement retirables manuellement. Ce qui induit un travail supplémentaire dangereux et ardu pour les opérateurs qui interviennent sur les machines ou dans les rouages et recoins difficilement accessibles. Par sécurité, la ligne de tri est complètement arrêtée, et cela peut prendre jusqu'à plusieurs heures pour traiter un bourrage. Cela entraîne une perte de productivité et de

volumes de déchets triés dans les temps impartis à cause de ces différentes contraintes.

Et les déchets coincés qui ont induit les bourrages ne sont pas remis dans le flux pour éviter de nouveaux bourrages et donc s'ajoutent au tas des déchets non triés.

Ainsi, les centres de tri de déchets ménagers rencontrent un problème majeur et persistant au tri des déchets ménagers non résolu, qui sont les bourrages des tapis convoyeurs (Figure 3). Détecter de potentiels bourrages est donc nécessaire. Ce travail cherche à vérifier la possibilité de détecter au plus tôt de potentiels bourrages sur des tapis convoyeurs, dans le but de maximiser la productivité du centre de tri et d'alerter les opérateurs au plus tôt.



Figure 3. Bourrage (par accumulation de déchets) en cours de formation sur un tapis convoyeur

Ainsi, les opérateurs pourront intervenir avant que le bourrage ne devienne trop difficile à débarrasser. Et ils n'auront donc pas à courir vers la machine problématique, car il y a seulement 2 opérateurs au maximum par centre de tri pour surveiller les deux cents machines. Et la plupart sont peu visibles et difficiles d'accès. Cela limitera les risques d'accidents et d'arrêts de production.

La seconde section détaille la problématique de détection des bourrages à partir de données réelles provenant d'un centre de tri en production. La troisième section explique le réseau de neurones artificiels auto-encodeur, soit la méthode mise en œuvre pour détecter les bourrages sur un tapis convoyeur témoin [Yokkampon et al., 2020]. Les données de tests et d'entraînement sont issues des données de production brutes historiques réelles. La section 4 délibère sur ces premiers résultats puis une conclusion aborde les perspectives futures.

La société Aktid a fourni les données sous contrainte de confidentialité limitant la divulgation complète de certaines informations.

2 PROBLEMATIQUE ET CONTRAINTES

Actuellement, suite à nos précédents travaux [You et al., 2022], un premier algorithme a été développé et est en cours de mise en production en centre de tri de déchets ménagers. Cependant, celui-ci utilise l'algorithme supervisé des k -plus proches voisins et demande donc de construire autant de jeux de données d'entraînements (comportant 5 classes dans ce cas précis), que de machines à comportements différents (tapis convoyeur, cribles, séparateurs balistiques, trieur optique, robot piqueur etc. avec des spécificités propres comme des capacités de charges différentes, un fonctionnement à sens unique ou à double sens, avec ou sans variateur de vitesse, avec une charge et donc un ampérage différent, avec des types de déchets à traiter différents...). De plus, il faut construire un jeu de données équilibré en classes et en sélectionnant un maximum de cas variés et représentatifs du comportement des machines. Or, plusieurs de ces classes sont difficiles à collecter, comme les bourrages qui sont peu nombreux par machine et les démarrages

qui ne durent que peu de temps. De plus, tous les bourrages ne sont pas systématiquement signalés et enregistrés dans la base de données par les opérateurs, comme ceux qui se sont décoincés tout seuls ou ceux non signalés par oubli, ou ceux décoincés manuellement avec une perche sans avoir eu à arrêter la ligne de tri. Et certaines machines ont quasiment une concentration des bourrages de l'année qui se produisent dans le même mois et les données sautent ou sont effacées régulièrement par des dysfonctionnements de fiabilité du côté des gestionnaires des bases de données. Il est donc difficile de construire un jeu de données spécifique par machine. Ensuite, certaines machines n'auront que deux bourrages enregistrés dans la base de données et cela ne suffira pas. D'autres au contraire cumuleront plus d'une centaine de bourrages, ce qui risquerait de déséquilibrer l'entraînement et le biais. Les démarrages sont plus nombreux que les bourrages, mais ils sont caractérisés par des pics d'intensité électrique de démarrage variés avec une grande amplitude pour une même machine, même pour des démarrages successifs rapprochés. Par conséquent, il y a trop de cas spécifiques et différents à collecter. Une autre contrainte de développement d'algorithme est qu'une seule donnée est disponible, l'intensité électrique moteur des machines brutes en ampère. Que ce soit pour des machines à variateur (moteur à vitesse variable, marche avant et arrière) ou à courant direct (moteur à vitesse constante, marche avant uniquement) et divers types de machines (tapis convoyeurs, cribles, trieurs optiques, robots...) avec divers types de flux de déchets à trier.

Le besoin de trouver un algorithme qui réduise le travail manuel et chronophage en amont qui est la collecte, la recherche, la sélection de données représentatives en plus de l'attente de nouvelles données pour réussir à construire des jeux d'entraînement équilibrés est crucial.

3 METHODE DE DETECTION DES BOURRAGES DES TAPIS CONVOYEURS

3.1 Modélisation et données

Le processus [Lee et al., 2021] de collecte, traitement et préparation des données a été schématisé sur la figure 4.

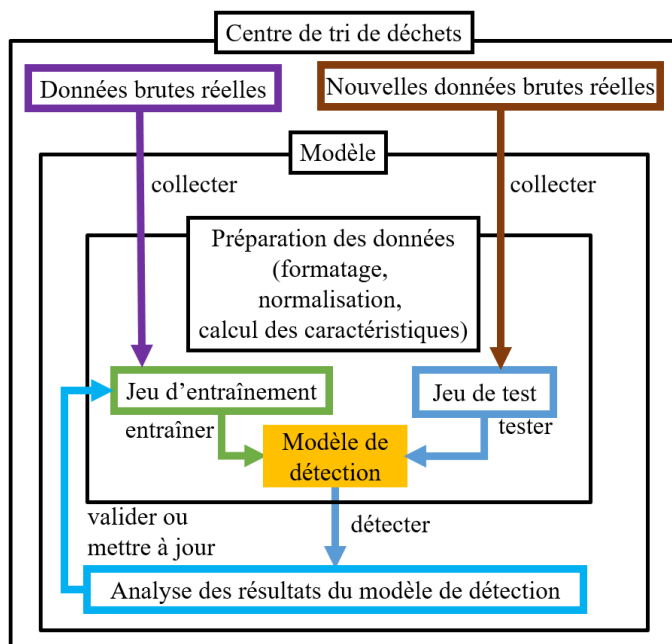


Figure 4. Schématisation du processus de développement d'un modèle de détection des bourrages

Les données brutes réelles provenant de l'historisation des données d'intensités électriques moteurs des machines concernées du centre de tri sont collectées sous la forme de série temporelles d'une valeur d'intensité en ampère par seconde. Elles sont ensuite traitées avec une normalisation et sont résumées en 7 caractéristiques qui seront appelées *features* du terme anglais pour correspondre à l'usage en Intelligence Artificielle et aux annotations dans les sections suivantes. Elles seront détaillées dans la section 3. Enfin, elles sont séparées en jeu d'entraînement et jeu de test pour la machine 1. Pour les machines 2 et 3 les données brutes réelles collectées sont aussi normalisées, mais elles sont seulement utilisées en jeux de tests. Le choix de la machine 1 en tant que machine témoin pour le développement du modèle est le résultat d'une décision commune entre les experts et les opérateurs en prenant en compte leur besoin réels sur site. C'est la machine qui cumule le plus de bourrages au total (en fréquence et en durée cumulée tout au long de l'année) et donc celle qui préoccupe le plus les opérateurs sur site et qui leur coûte du temps en patrouille et débouillage manuel. De plus, sur celle-ci l'opérateur a une bonne visibilité et la surveillance de près à cause des bourrages fréquents. Cela n'est pas négligeable pour obtenir l'adhésion à l'utilisation de l'algorithme et pour obtenir les retours utilisateurs provenant des opérateurs lors de futures phases de tests en temps réel sur site. Elle a aussi été sélectionnée comme étant celle qui possède les courbes d'intensité électrique les plus représentatives des états de fonctionnement normal et des états de fonctionnement en bourrage avec le moins de bruits (Figure 5). C'est une machine de type tapis convoyeur à sens unique et à courant moteur direct, soit avec une vitesse constante et donc avec une courbe avec des intensités électriques sans fortes oscillations où les bourrages sont plus aisément identifiables post-événements. La machine 2 est aussi un convoyeur à sens unique et à courant moteur direct, mais traite un flux de déchets différent et est caractérisée par une plage d'ampérage complètement différente de la machine 1 (Figure 8). Cette machine 2 est sélectionnée dans le but de tester l'hypothèse suivante : est-ce qu'un modèle entraîné sur une seule machine peut être appliqué à une autre machine caractérisée par une forme de courbe d'intensité électrique similaire ?

La machine 3 est complètement différente des machines 1 et 2, c'est un tapis convoyeur à vitesse variable et à double sens, traitant des déchets différents et à fortes oscillations au niveau des courbes d'intensités (Figure 9). Son choix est motivé par le but de tester l'hypothèse suivante : est-ce qu'un modèle entraîné sur une seule machine peut être appliqué à une autre machine caractérisée par une forme de courbe d'intensité électrique totalement différente ?

Ces deux hypothèses permettent de déterminer si le modèle réussit à couvrir un maximum de tapis convoyeurs différents. Actuellement, il n'est pas possible d'obtenir d'autres données utilisables provenant des centres de tri, pour diverses raisons (données manquantes, non collectées, fautes de moyens, confidentielles...).

Ensuite le modèle est entraîné avec les données d'entraînement de la machine 1. Puis il est testé sur la machine 1 et si le modèle n'est pas satisfaisant, il faut réitérer depuis la collecte mais seulement pour la machine 1 et pour le jeu d'entraînement. Le but de ces itérations est d'améliorer le modèle en modifiant le jeu d'entraînement. Il faut ensuite préparer à nouveau les données pour le modèle. Et le tester jusqu'à validation lorsque les résultats de détection sont satisfaisants sur le jeu de test de la machine 1. Ensuite le modèle est testé avec les mêmes paramètres sur les machines 2 et 3 et les résultats sont observés.

3.2 Annotations et définitions

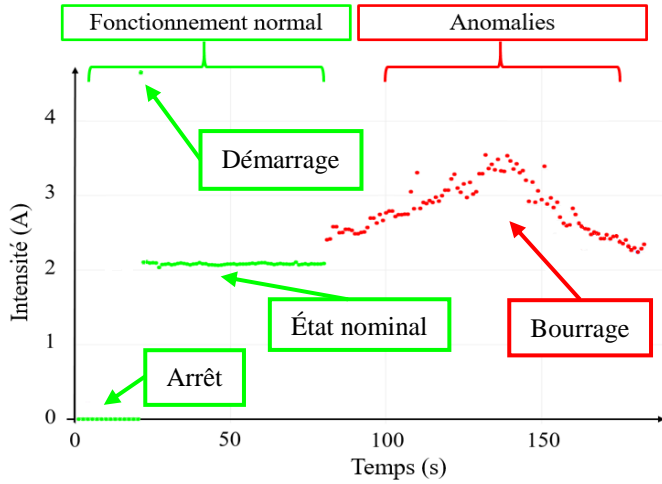


Figure 5. Données normales et données de bourrages

Les données mises à disposition par le centre de tri peuvent être différenciées en données de fonctionnement normal et données d'anomalies. Les données normales sont les données collectées les jours où aucun bourrage n'a été enregistré par les opérateurs du centre de tri. Et les données d'anomalies sont les données des jours de fonctionnement où au moins un bourrage a été enregistré par les opérateurs du centre de tri. Dans la figure 5, deux exemples représentatifs ont été accolés pour montrer la différence entre un état de fonctionnement considéré normal en vert et un bourrage en rouge. Seules les données de fonctionnement normal de la machine 1 sont utilisées pour l'entraînement du modèle auto-encodeur. Cela signifie que l'on cherche à construire un modèle dit de bon fonctionnement représentant le fonctionnement normal de la machine 1. Et tout comportement non cohérent avec ce modèle conduira à la détection d'une anomalie (un bourrage dans notre cas). Les données normales sont composées de période d'arrêts et des démarrages en état de fonctionnement normal, ainsi que des périodes de fonctionnement normal proche de l'état nominal de la machine 1. Ce qui correspond aux périodes de données en fonctionnement normal entre un démarrage et un arrêt de la machine 1. Les jeux de tests seront eux constitués autant de données correspondant à un fonctionnement normal que de données associées à un bourrage, afin de tester les performances de l'auto-encodeur. À noter qu'il est important de construire un jeu d'entraînement équilibré en faisant attention à avoir des parts égales de données d'état d'arrêt, démarrage, et nominal, pour ne pas biaiser le modèle. Cette règle d'équilibrage s'applique aussi sur les données en état nominal, où il faut bien faire attention à construire une période nominale en prenant une moitié des données qui sont des données nominales succédant à un démarrage et l'autre moitié qui précèdent un arrêt, en respectant la chronologie des événements réels.

Pour construire un jeu d'entraînement, les données brutes d'intensités moteur à la seconde sont collectées sous forme de séries chronologiques. Une série chronologique est une séquence ordonnée dans le temps de valeurs qui représente l'évolution d'une même observation. Une série chronologique univariée enregistre une seule valeur pour chaque instant [Rajpurkar et al., 2017]. Dans cet article, une série chronologique est définie par $V_i = v_{(hi)}$ [You et al., 2022], avec i l'index de temps, h avec $h = 10$ secondes la taille de la fenêtre de la série chronologique V_i et v_i la valeur d'intensité

électrique moteur normalisée par rapport au fonctionnement à l'état nominal de la machine concernée à l'instant i .

La formule de normalisation est la suivante :

$$v_i = (v_{i,b} - v_{min}) / (v_{nominal} - v_{min})$$

avec v_i les données normalisées, $v_{i,b}$ les données brutes mesurées, $v_{min} = 0$ (état arrêt) et $v_{nominal}$ la moyenne des données brutes en fonctionnement nominal. L'objectif de cette normalisation est de pouvoir réutiliser un même jeu d'entraînement sur différentes machines.

La série chronologique $V_i = v_{(hi)}$ peut donc être représentée par le vecteur $[v_{i-h+1}, \dots, v_{i-1}, v_i]$. L'horizon temporel h a été déterminé par itérations de tests pour respecter le compromis entre une taille faible pour limiter le retard à la détection et une taille suffisante pour filtrer les bruits sur les mesures récoltées. Ensuite, 7 caractéristiques (appelées *features* en anglais dans le vocabulaire des modèles d'Intelligence Artificielle) caractérisant V_i sont calculées pour chaque V_i , avec $f_i^n \in [\text{'minimum'}, \text{'maximum'}, \text{'moyenne'}, \text{'médiane'}, \text{'pente'}, \text{'ordonnée à l'origine'}, \text{'écart-type'}]$. Ce qui introduit le vecteur de features F_i défini par $[f_i^1, f_i^2, \dots, f_i^7]$. Les exposants $*^{train}$ et $*^{test}$ des séries chronologiques V_i^* et de leurs classes C_i^* indiquent quel jeu de données est utilisé. Seules les variables caractérisant F_i^{train} et la classe C_i^{train} de chaque série V_i^{train} sont utilisées pour l'entraînement du modèle auto-encodeur.

Le jeu de données d'entraînement F_i^{train} et le jeu de données de test F_i^{test} sont construits en assemblant différents sous-ensembles de données, chacun représentatif d'un état de fonctionnement normal ou bourrage selon le jeu de données à construire.

Pour chaque série chronologique, un vecteur de classe défini par $C_{(hi)} = [c_{i-h+1}, \dots, c_{i-1}, c_i]$ lui est assigné, avec $c_i \in [\text{'normal'}, \text{'bourrage'}]$ correspondants aux états de fonctionnement normal et anormal associés aux valeurs d'intensités v_i . Il s'ensuit que pour chaque vecteur F_i est associée une classe $c_i \in [\text{'normal'}, \text{'bourrage'}]$. Les h classes dans $C_{(hi)}$ sont toutes identiques, et la dernière classe c_i de $C_{(hi)}$ détermine directement la classe C_i de la série chronologique V_i .

Pour la prise de décision lors de la phase de test, un seuil permettant de déterminer si les données sont proches ou non du modèle de fonctionnement normal de l'auto-encodeur est nécessaire. Ce seuil t^{train} est calculé à partir des données d'entraînement de la façon suivante :

$$t^{train} = \frac{(\overline{F_{i,enc}^{train}} - \overline{F_{i,dec}^{train}}) + \sigma(F_{i,enc}^{train} - F_{i,dec}^{train})}{2}$$

où les opérateurs $(\overline{\quad})$ et $\sigma(\quad)$ désignent la moyenne et l'écart-type des termes entre parenthèses et où $F_{i,enc}^{train}$ sont les données entrantes encodées et $F_{i,dec}^{train}$ sont les sorties du modèle, c'est-à-dire les données reconstruites à partir du code par le décodeur (Figure 6). Ce seuil t^{train} est calculé uniquement à partir des données d'entraînement et sera utilisé ensuite pour toutes les machines à tester. Ainsi, pour la détection sur les données de tests, la moyenne m^{test} définie par :

$$m^{test} = \frac{(\overline{F_{i,enc}^{test}} - \overline{F_{i,dec}^{test}})}{2}$$

entre les données de tests entrantes F_i^{test} encodées et les données de tests sortantes F_i^{test} décodées est calculée puis soumise au seuil t^{train} . Si $m^{test} < t^{train}$ alors la classe C_i de F_i est déclarée ['normal'] ce qui est un état de fonctionnement normal, sinon c'est un état de bourrage et C_i de F_i est assignée ['bourrage'].

L'auto-encodeur permet d'évaluer les performances de la détection des bourrages en comparant la première occurrence de C_i de $F_i \in [\text{'bourrage'}]$ à l'horodatage du bourrage enregistré par les opérateurs dans la base de données.

3.3 Réseau de neurones artificiels auto-encodeur

Pour expliquer ce qu'est un réseau de neurones auto-encodeur, il faut rapidement rappeler les notions de réseau de neurones et ce qu'est un neurone. Un réseau de neurones ou neuronal est un système du domaine de l'Intelligence Artificielle s'inspirant du fonctionnement des neurones biologiques du cerveau humain, qui apprend à traiter les données [Hopfield, (1982)]. Les réseaux de neurones font partie du sous-ensemble de l'apprentissage machine (en anglais *machine learning*) appelé apprentissage profond (en anglais *deep learning*). C'est tout d'abord un réseau de couches composées de neurones ou nœuds interconnectés (Figure 6) et la plupart des réseaux de neurones ont chaque couche forcément interconnectée pour passer les données et l'information.

Les données à traiter par le réseau de neurones se propagent de l'entrée du réseau à la sortie par les différentes couches de neurones avec un sens de propagation de la couche d'entrée vers la couche de neurones suivantes, et il est aussi possible de rajouter un retour de l'information. Il en existe une trentaine de répertoriés par architecture, sans en compter leurs variantes [Van Veen & Leijnen, 2019], et de nouveaux en voient le jour chaque année. Dans la figure 6, les ronds représentent les neurones ou nœuds et les lignes représentent les connexions neuronales entre les couches et neurones et la propagation de l'information. Les changements de couleurs permettent une meilleure visualisation du fait que les données se transforment à chaque étape.

Chaque connexion entre deux neurones est le résultat de calculs composé de poids, biais et d'une fonction d'activation qui aide à approximer les données transférées par propagation (en anglais *forward propagation*) dans le neurone suivant. Puis le réseau de neurones itère en utilisant l'erreur entre la donnée en entrée et celle de sortie propagée jusqu'à que l'erreur (et donc apprise par entraînement) soit minimale. Cela s'appelle la propagation inverse (en anglais *backward propagation* ou *backpropagation*). C'est donc un système adaptatif qui apprend de ses erreurs pour s'améliorer.

Les réseaux neuronaux artificiels sont utilisés sur des problèmes complexes, les plus connus sont résumés des documents en masse pour en obtenir des informations utiles à la génération de textes des chatbot et documents par exemple, ou reconnaître des visages sur des images avec le maximum de précision avec des jeux de données importants.

L'auto-encodeur est un réseau de neurones non supervisé et son rôle est de répliquer son entrée à la sortie. L'auto-encodeur le plus simple est composé de 3 couches de neurones (Figure 6) : la couche d'entrée des données, la couche des données encodées, la couche des données décodées en sortie. Et le réseau de connexions entre la couche d'entrée et la couche de code (aussi appelé la couche cachée) est appelé l'encodeur, et respectivement entre la couche de code et des sorties, c'est le décodeur. L'auto-encodeur apprend donc des représentations compressées en retenant ce qu'il considère pertinent à la projection de l'entrée vers la sortie, qui sont ensuite décodées pour projeter les données d'origine en sortie [Mienye et al., 2020]. La couche de code correspond aux données d'entrée « compressées » qui sont prêtes à être décodées par le décodeur pour obtenir les données en sortie.

Pour les expérimentations la bibliothèque de développement en apprentissage profond Keras [Chollet, 2016] et le code mis à disposition dans la documentation a été pris en tant que base de développement [Pavithra et Keras, 2020] avec le langage de programmation Python [Chollet, 2021] sur un ordinateur portable avec la configuration suivante : Intel(R) Core(TM) i7-8550U CPU @ 1.80GHz, 1.99 GHz, RAM 32,0 Go.

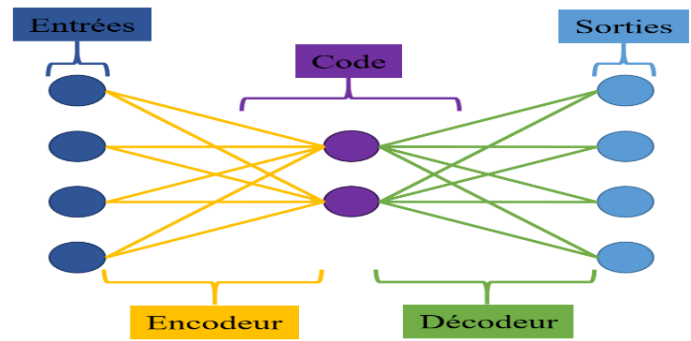


Figure 6. Représentation simplifiée du réseau de neurones artificiels auto-encodeur de détection des bourrages

3.4 Démarche d'entraînement et validation de l'auto-encodeur

Les performances du modèle sont évaluées graphiquement en comparant l'horodatage du bourrage enregistré dans la base de données par l'opérateur sur site et la première occurrence de détection en anomalie par l'auto-encodeur de F_i avec $C_i \in [\text{'bourrage'}]$. Une matrice de confusion n'est pas pertinente car tous les bourrages enregistrés ont été détectés et la priorité est de savoir si l'auto-encodeur arrive à détecter en amont de l'horodatage. Une validation par des experts est ensuite effectuée graphiquement sur la validité des détections en amont sur les courbes d'intensités électriques des machines testées. La priorité des opérateurs est de limiter le nombre de bourrages non détecté, soit limiter le nombre de faux négatifs [Sokolova et Lapalme, 2009]. Le modèle est validé et sauvegardé lorsque le nombre de bourrages correctement détecté est à son maximum possible. C'est-à-dire que les itérations et expérimentations sont arrêtées pour cet article.

4 RESULTATS EXPERIMENTAUX DE L'AUTO-ENCODEUR

4.1 Résultats sur la machine 1 témoin

L'auto-encodeur s'entraîne sur un jeu de données d'entraînement de 1006 vecteurs de caractéristiques non annotées F_i^{train} construit sur la machine 1. Pour valider les expérimentations, le modèle a été testé sur des journées de travail complètes, soit 7h30, soit 27 000 F_i^{test} par machine. Les figures 7,8,9 sont des zooms sur ces tests représentant tous les états à détecter (arrêt, démarrage, nominal, bourrage) pour plus de lisibilité.

La machine 1 est un tapis convoyeur à courant moteur direct à sens de marche unique, et qui traite tous les refus du centre de tri avec un ampérage nominal aux alentours de 2 A. Les résultats sur la machine 1 qui sert de témoin, soit celle sur laquelle deux jeux de données distincts ont été construits : un jeu d'entraînement, et un jeu de test, montrent que l'auto-encodeur arrive à détecter le fonctionnement normal et le bourrage signalé et enregistré dans la base de données par les opérateurs sur site. Pour rappel, l'opérateur enregistre seulement l'horodatage à l'instant où il arrête la machine suite à un bourrage confirmé, ici à 7:02:28. L'auto-encodeur détecte la première anomalie (Figure 7) à 6:57:45, soit 4:43 en amont sur de nouvelles données sur lesquelles il n'y a pas eu d'entraînement. Certains points des zones qui semblent de fonctionnement normal sont détectés en bourrage, mais cela peut s'expliquer par le fait que l'algorithme a été entraîné avec des séries temporelles, et donc sur des données possédant des bourrages, il y aura forcément des points qui résultent d'un chevauchement entre l'état normal et l'état bourrage. Et pour ces premières expérimentations, les données en état de fonctionnement normal du modèle n'avaient pas de tel pic d'ampérage de démarrage machine. Cela permet

donc d'observer qu'il pourrait être utile d'enrichir le jeu d'entraînement avec ce type de comportement au démarrage.

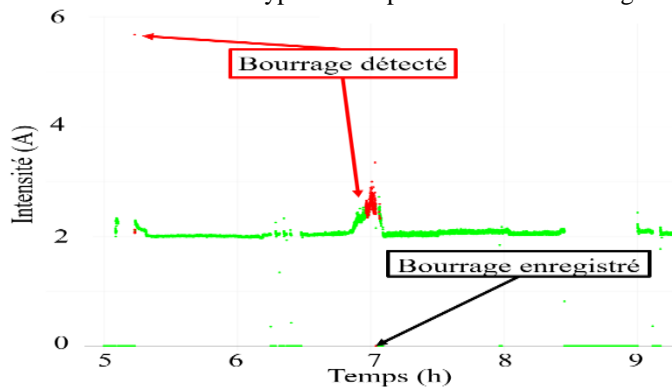


Figure 7. Résultats de détection des bourrages sur le tapis convoyeur témoin (machine 1)

4.2 Résultats sur la machine 2 différente du modèle

La machine 2 sert de test, c'est aussi un tapis convoyeur à courant moteur direct et aussi à sens de marche unique, mais qui n'a pas du tout le même ampérage ni les mêmes déchets à traiter, et avec un ampérage nominal aux alentours de 5,5 A. Les résultats montrent que l'auto-encodeur appris sur la machine 1 uniquement arrive à détecter le fonctionnement normal et le bourrage enregistré dans la base de données par les opérateurs sur site, grâce à la normalisation des données lors de l'étape de préparation des données. Ici, l'opérateur a enregistré le bourrage confirmé à 14:52:08 (Figure 8). L'auto-encodeur détecte la première anomalie à 14:48:45, soit 3:23 en amont sur de nouvelles données sur lesquelles il n'y a pas eu d'entraînement. On retrouve les mêmes tendances en termes de résultats que pour la machine 1, à savoir des zones qui semblent de fonctionnement normal sont détectées en bourrage et des démarrages vus ponctuellement comme des débuts de bourrage sur de courts instants.




Figure 8. Résultats de détection des bourrages sur un tapis convoyeur différent (machine 2)

4.3 Résultats sur la machine 3 complètement différente

La machine 3 sert aussi de test, c'est une machine qui est aussi un tapis convoyeur mais à courant moteur variable (présence d'un variateur de vitesse), à double sens de marche, et qui n'a pas du tout le même ampérage ni les mêmes déchets à traiter, avec un ampérage nominal aux alentours de 3 A, mais surtout avec de fortes oscillations (signaux nettement plus bruités). Les résultats montrent que l'auto-encodeur appris sur la machine 1 uniquement arrive à distinguer le fonctionnement normal et le bourrage. Cependant, l'opérateur a enregistré le bourrage confirmé à 15:33:13 (Figure 9). Et l'auto-encodeur détecte le

bourrage enregistré à 15:35:08, soit 1:55 en retard. Ce qui n'est pas très utile à l'opérateur. En revanche, il aurait été préférable que l'auto-encodeur détecte dès l'encadré bleu. Cela permet donc d'observer qu'il faudra créer un jeu d'entraînement spécifique à cette machine, même si ce premier résultat rend l'utilisation de l'auto-encodeur prometteur sur cette machine.

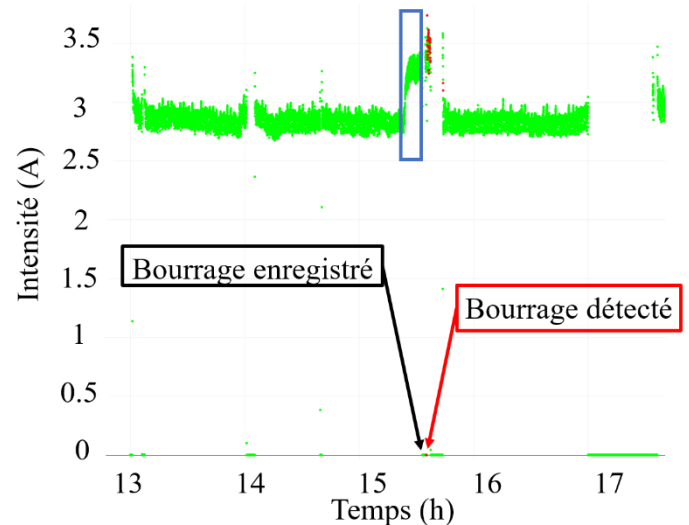


Figure 9. Résultats de détection des bourrages sur un tapis convoyeur différent (machine 3)

5 CONCLUSION ET POTENTIELS FUTURS TRAVAUX

Les aspirations de ce travail sont d'observer s'il est possible de détecter de potentiels bourrages avant les opérateurs de production. Mais également de gagner du temps sur la préparation des jeux d'entraînement en utilisant un algorithme d'apprentissage non supervisé sur uniquement des données considérées comme un état de fonctionnement normale de la machine, qui sont plus aisément disponibles que les cas représentant les anomalies. Effectivement, d'après ces premiers résultats, le réseau de neurones artificiels auto-encodeur détecte les potentiels bourrages avant que les opérateurs interviennent pour arrêter la machine (d'après l'horodatage de l'arrêt suite à un bourrage enregistré dans la base de données par les opérateurs).

Une des contributions principales est qu'il est possible de construire plus rapidement et sans nécessiter systématiquement l'aide d'expertise humaine, un jeu de données d'entraînement spécifique à une machine. Et donc potentiellement la possibilité par extrapolation de construire autant de modèles nécessaires que de machines, avec chaque modèle adapté à la machine sur laquelle il aura appris. Il faudra néanmoins vérifier si les résultats sont acceptables par les opérateurs sur site qui restent les utilisateurs finaux.

Une seconde forte contribution est qu'il est possible d'appliquer le même modèle sur une machine différente tant qu'elle a un comportement similaire, voir machine 1 et 2 (Figure 7 et 8), même si elle traite différents flux de déchets et ont des ampérages nominaux différents. C'est un gain de temps capital sur l'entièreté du processus de développement d'un modèle de détection. Si le comportement est trop éloigné de la machine qui a servi à l'entraînement et la construction du modèle, alors la détection ne fonctionne pas correctement. Comme pour la machine 3 à moteur variateur, dont la vitesse peut varier et qui possède une marche avant et arrière et qui présente de fortes oscillations. Dans ce cas, il sera préférable de construire un nouveau modèle.

Les perspectives sont d'essayer de définir des critères de groupement de machines avec des comportements en état normal de fonctionnement similaires, et de tester un modèle auto-encodeur pour chacun de ces groupes et d'évaluer leurs performances respectives.

Toutefois, il faudra prêter attention à l'évolution des comportements des machines dans le temps. De par leurs vieillissements et des maintenances non répertoriées qui auront été effectuées. Et d'autre part, si les opérateurs utilisent les détections de l'auto-encodeur et arrêtent les machines dès une détection de bourrage, alors les comportements de ces machines évolueront et il faudra sûrement régénérer de nouveaux modèles pour détecter de nouvelles anomalies.

Et pour répondre au travail chronophage du processus de construction de modèles, il faudra essayer un algorithme qui permette de suivre l'évolution des machines dans le temps en complément des résultats de l'auto-encodeur, comme l'apprentissage par renforcement [Seo et al., 2023] et/ou un apprentissage automatique adaptatif (en anglais *online learning*) [Vaughan et al., 2015].

6 REMERCIEMENTS

Nous remercions l'entreprise Aktid pour la mise à disposition des données et leur expertise, ainsi que les opérateurs sur site. Aktid construit et assemble des centres de tri et de valorisation des déchets [Aktid, 2018].

7 REFERENCES

Ademe. (2020). *Déchets Chiffres-clés - Edition 2020*.

La librairie ADEME.

Aktid. (2018). Aktid. <https://aktid.fr>

Chollet, F. (2016). Building autoencoders in keras. *The Keras Blog*, 14.

Chollet, F. (2021). *Deep learning with Python*. Simon and Schuster.

Dilmi, M. D. (2019). *Méthodes de classification des séries temporelles: application à un réseau de pluviomètres* (Doctoral dissertation, Sorbonne université).

Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*, 79(8), 2554-2558.

La Région Auvergne-Rhône-Alpes. (2022, décembre 12). Zéro enfouissement des déchets d'ici 2030. <https://www.auvergnerhonealpes.fr/actualites/zero-enfouissement-des-dechets-dici-2030>

Lee, T. H., Skofteland, G., & Lundteigen, MA. (2021). Performance Management of Safety Instrumented Systems for Unmanned Facilities Using Machine Learning: Decision Support System for SIS. *Proceedings of the 31st European Safety and Reliability Conference (ESREL 2021)*, University of Angers, France, 2878-85. Research Publishing Services.

Mienye, I. D., Sun, Y., & Wang, Z. (2020). Improved sparse autoencoder based artificial neural network approach for prediction of heart disease. *Informatics in Medicine Unlocked*, 18, 100307.

Organisation for Economic Co-operation and Development OECD. (2022). *Global Plastics Outlook: Policy Scenarios to 2060*. OECD Publishing

Pavithra, V., & Keras. (2020). Keras documentation: Timeseries anomaly detection using an Autoencoder.

Rajpurkar, P., Hannun, A. Y., Haghpanahi, M., Bourn, C., & Ng, A. Y. (2017). Cardiologist-level arrhythmia detection with convolutional neural networks. *arXiv preprint*

arXiv:1707.01836.

Seo, G., Yoon, S., Song, J., Srivastava, E., & Hwang, E. (2023). Label-Free Fault Detection Scheme for Inverters of PV Systems: Deep Reinforcement Learning-Based Dynamic Threshold. *Applied Sciences*, 13(4), 2470.

Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, 45(4), 427-437.

Van Veen, F., & Leijnen, S. (2019). A mostly complete chart of Neural Networks. *The Neural Network Zoo*. Retrieved December, 28, 2020.

Vaughan, A., & Bohac, S. V. (2015). Real-time, adaptive machine learning for non-stationary, near chaotic gasoline engine combustion time series. *Neural Networks*, 70, 18-26.

Yokkampon, U., Chumkamon, S., Mowshowitz, A., & Hayashi, E. (2020). Autoencoder with Spiking in Frequency Domain for Anomaly Detection of Uncertainty Event. *J. Robotics Netw. Artif. Life*, 6(4), 231-234.

You, C., Adrot, O., & Flaus, JM. (2022). Jam detection in waste sorting conveyor belt based on k-Nearest Neighbors. In *Leva, M.C., Patelli, E., Podofillini, L. and Wilson, S. (©2022 ESREL2022 Organizers), Proceedings of the 32nd European Safety and Reliability Conference (ESREL 2022)*, 8. Research Publishing, Singapore.