



## **MORPHO-IA: IA et Digital Twin au service de la maintenance prédictive**

### **RAPPORT INTERMEDIAIRE Novembre 2021**

<b>REDIGÉ PAR</b>	<b>VALIDÉ PAR</b>	<b>APPROUVÉ PAR</b>
Anaïs MILHIET Rubal RAVINDER	Date : 24/11/2021  Loïc GRAU	Date : 24/11/2021  Cyril CONDEMINE

**LISTE DE DIFFUSION**

<b>Société</b>	<b>Contact</b>
MORPHOSENSE 22 Rue des Platanes 38120 Saint-Egrève	Rubal RAVINDER Cyril CONDEMINE
Fondation FEREC	Dominique CHEVILLARD Thibault PREVOST Gilles SAUSSINE

## Table des matières

<b>1</b>	<b>Introduction .....</b>	<b>5</b>
<i>1.1</i>	<i>Présentation de l'entreprise</i>	<i>5</i>
<i>1.2</i>	<i>Le projet</i>	<i>6</i>
<i>1.3</i>	<i>La Passerelle Saint-Laurent</i>	<i>7</i>
<i>1.4</i>	<i>Le système Neuron de Morphosense</i>	<i>7</i>
<b>2</b>	<b>Programme de travail.....</b>	<b>9</b>
<i>2.1</i>	<i>Objectifs et résultats attendus</i>	<i>9</i>
<i>2.2</i>	<i>Budget et planning</i>	<i>10</i>
<b>3</b>	<b>Instrumentation de la Passerelle Saint-Laurent, Grenoble.....</b>	<b>12</b>
<b>4</b>	<b>Données récoltées par le système Neuron sur la Passerelle Saint-Laurent .....</b>	<b>14</b>
<i>4.1</i>	<i>Caméra</i>	<i>14</i>
<i>4.2</i>	<i>Nœuds de mesure du système Neuron</i>	<i>14</i>
<i>4.3</i>	<i>Station météo</i>	<i>16</i>
<b>5</b>	<b>Quelques notions d'IA .....</b>	<b>16</b>
<b>6</b>	<b>Résultats de l'étude de la Passerelle Saint-Laurent.....</b>	<b>17</b>
<i>6.1</i>	<i>Détection de piétons</i>	<i>17</i>
<i>6.2</i>	<i>Détection d'outliers</i>	<i>21</i>
<i>6.3</i>	<i>Détection de nouveautés</i>	<i>23</i>
<i>6.3.1</i>	<i>Prédiction de la température ambiante en fonction des températures internes des nœuds de mesure</i>	<i>23</i>
<i>6.3.2</i>	<i>Etude de l'impact de la température sur les variations de la structure pour la détection d'anomalie</i>	<i>24</i>
<i>6.4</i>	<i>Labélisation des événements présents dans les séries temporelles</i>	<i>26</i>
<i>6.4.1</i>	<i>Effet des conditions météorologiques sur la passerelle</i>	<i>26</i>
<i>6.4.2</i>	<i>Effet des piétons sur l'accélération</i>	<i>26</i>
<b>7</b>	<b>Conclusion .....</b>	<b>27</b>

## Table des figures

Figure 1: Historique de Morphosense .....	5
Figure 2: Briques technologiques Morphosense .....	6
Figure 3 : Localisation géographique de la Passerelle Saint-Laurent (entourée en rouge) .....	7
Figure 4: Schéma simplifié du système Neuron comportant (n+2) nœuds de mesure reliés en série.....	8
Figure 5: Tâches du projet.....	9
Figure 6: Budget projet .....	10
Figure 7: Planning projet.....	11
Figure 8 : Fixation de la station météo, de la caméra de comptage et des nœuds de mesure sur les haubans. ....	11
Figure 9 : Vue d'ensemble du positionnement des composantes du système Neuron sur la passerelle Saint-Laurent, Grenoble .....	12
Figure 10: Exemple d'image capturée par la caméra sur la passerelle Saint-Laurent .....	13
Figure 11 : Exemple de visualisation de l'inclinaison des nœuds du tablier .....	14
Figure 12 : Exemple de visualisation de l'écart type des accélérations en z des nœuds du tablier .....	14
Figure 13 : Exemple de visualisation de la déformation maximale du tablier en un point .....	15
Figure 14 : Exemple de visualisation du suivi des fréquences modales de la structure.....	15
Figure 15 : Exemple de visualisation des données provenant de la station météo avant son remplacement.....	16
Figure 16 : Comparaison des pourcentages de détection d'algorithmes de détection de piétons selon la taille des images données en entrée .....	17
Figure 17 : Comparaison du temps de calcul pour une détection des algorithmes .....	18
Figure 18 : Comparaison du pourcentage de détection de l'algorithme YOLO par rapport à la taille des images .....	19
Figure 19: Exemple de détection par YOLO de cyclistes(gauche) et de piétons (droite).....	19
Figure 20 : Détection multiple objets avec YOLO .....	20
Figure 21: Visualisation du résultat de détection d'outlier de l'algorithme DBSCAN sur un mois de données et sur 4 nœuds de mesure .....	21
Figure 22: Superposition entre les températures internes des nœuds du tablier (noir) et la température ambiante (turquoise) pour chaque jour sur 28 jours de données.....	22
Figure 23 : Exemple de prédiction de la température ambiante en fonction des températures internes des nœuds de mesure du tablier.....	23
Figure 24 : Comparaison de la déformée maximale en un point de la structure par rapport aux températures internes et externes de la station météo.....	24
Figure 25: Comparaison entre les "vraies" valeurs de flèche et celles prédites par l'algorithme d'apprentissage automatique sur 6 jours de données.....	24
Figure 26: Visualisation de la corrélation entre l'écart-type des accélérations des nœuds des câbles et la vitesse du vent.....	25
Figure 27 : Visualisation de la corrélation entre la moyenne de l'écart-type des accélérations des nœuds de la structure métallique avec le nombre de piétons détectés sur la passerelle .....	26

# 1 Introduction

## 1.1 Présentation de l'entreprise

MORPHOSENSE est une startup technologique issue du CEA Grenoble et créée en 2016 (Figure 1). Elle compte aujourd'hui 20 salariés et se situe à Saint Egrève (Isère) et au Bourget du Lac (Savoie).



Figure 1: Historique de Morphosense

Morphosense conçoit et développe une solution intégrée de maintenance prédictive des structures permettant :

- Leur monitoring à travers des indicateurs statiques (déformée, torsion) et dynamiques (accélérations, vibrations, fréquences propres, modes propres),
- L'estimation de la fatigue, de l'endommagement, et de la durée de vie résiduelle des structures instrumentées et du Digital Twin de Morphosense.

Pour cela, elle repose sur :

- Un réseau de capteurs filaires distribué sur la structure (Technologie NEURON),
- Un Digital Twin hybride et temps réel basé sur un modèle couplant physique et I.A (Technologie Live Hybrid Digital Twin).

Ainsi, Morphosense a pour ambition de permettre à ses clients de devenir autonomes dans la gestion de la durée de vie de leurs actifs, en leur permettant :

- De réduire les coûts de maintenance et les risques d'exploitation,
- De garantir une continuité d'exploitation,
- De mesurer la sécurité d'une installation.

Notre solution s'appuie sur 4 briques technologiques décrites par la figure 2 ci-dessous :

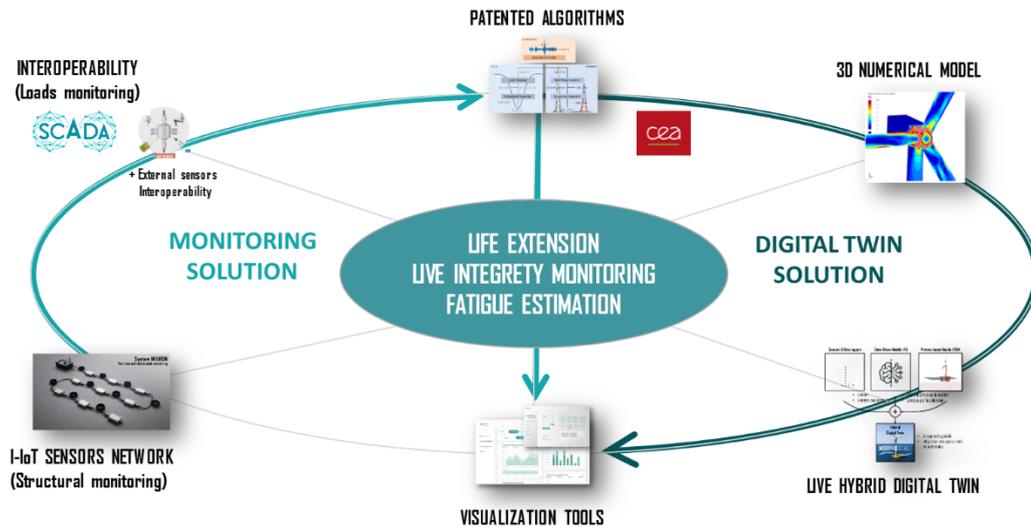


Figure 2: Briques technologiques Morphosense

**1-Notre réseau de capteurs** intègre jusqu'à 40 nœuds de mesure et peut se déployer sur 1 km. Les nœuds sont robustes et qualifiés IP65 / 68 ou ATEX Z21 et sont certifiés CE. Nous proposons une interopérabilité avec tous types de capteurs existants (analogique, numérique, jauge de contrainte, station météo, ...) que nos clients ont déjà installés sur leurs structures ou souhaitent ajouter.

**2-Nos algorithmes brevetés** nous permettent de calibrer les nœuds et de produire des indicateurs statiques (reconstruction de la forme, mesure de convergences) ou dynamiques (analyse modale, vibratoire) du comportement de la structure.

**3-Le Live Hybrid Digital Twin** basé sur un modèle numérique 3D de la structure et associé à une intelligence artificielle pour la convergence modèle-mesure, permet d'avoir une copie précise et à jour des propriétés et des états de la structure suivie. Notre Digital Twin évolue en temps réel en fonction des charges (contraintes environnementales) et de l'endommagement subis par la structure (fissure, boulons cassés, ...). Il nous permet de proposer une estimation de la fatigue, de l'endommagement et de la durée de vie résiduelle de la structure monitorée basé sur une explication physique des phénomènes observés. Nos clients peuvent ainsi optimiser la maintenance en fonction de l'état réel de la structure.

**4-Afin d'exploiter au mieux les indicateurs calculés**, nous avons redéveloppés des **outils de visualisation** des données, sous formes d'outils WEB dédiés, accessibles par nos clients n'importe où dans le monde et à tout instant. Ils s'appuient sur une architecture de Cloud Computing à l'état de l'art et une base de données spécifique permettant un accès rapide et fluide à l'ensemble des données.

## 1.2 Le projet

Le projet MORPHO-IA, développé au sein de Morphosense, a pour objectif de créer différents modules basés sur des méthodes d'apprentissage automatique. Ces modules auront différents usages :

- Labélisation manuelle de données afin d'appliquer plus « facilement » les algorithmes d'apprentissage automatique,
- Labélisation automatique des données pour connaître les sources sollicitant la structure afin de les utiliser en entrée du Digital Twin (DT),

- Détection d'outlier/nouveauté afin de remonter les données différentes ou aberrantes,
- Clusterisation des données afin de faire ressortir les nouveaux événements,
- Prédiction des futures données et leur comparaison avec le flux de données.

Ce projet permettrait à Morphosense de pouvoir exploiter l'IA (Intelligence Artificielle) au service de la maintenance prédictive afin d'améliorer les services que l'entreprise propose à ses clients.

Il utilise le système d'acquisition qui a été déployé sur la passerelle Saint-Laurent à Grenoble dans le cadre du projet R&D Booster pour avoir accès à une grande base de données. Ce projet est financé par la région AuRA (Auvergne Rhône-Alpes) et a pour but la création d'un DT d'une passerelle piétonne. Ce DT est un avatar numérique représentant le comportement complet d'une structure en temps réel. Ce jumeau numérique permet alors d'extraire de nouvelles informations qui ne sont pas directement accessibles par la mesure telles que la contrainte en tout point ou le suivi de l'endommagement d'éléments bien localisés de l'ouvrage.

### 1.3 La Passerelle Saint-Laurent

La passerelle Saint-Laurent, située au centre de la ville de Grenoble, a été construite en 1837 avec l'objectif de remplacer l'ancien pont en bois construit au Moyen Âge. Ce pont, emprunté par des voitures et des piétons depuis sa création, a été rendu exclusivement piéton en 1909 lors de sa consolidation.

En 2017, la Métropole de Grenoble, en charge de cet ouvrage depuis 2015, décide de le rénover dans le but d'assurer la sécurité des centaines de piétons qui l'empruntent quotidiennement. La passerelle Saint-Laurent a par conséquent été fermée au public le 2 octobre 2017 afin de réhabiliter l'ouvrage, principalement endommagé par une corrosion importante sur ses parties latérales. Aujourd'hui, ce pont fait partie de l'aire de valorisation de l'architecture et du patrimoine (AVAP)[1].



*Figure 3 : Localisation géographique de la Passerelle Saint-Laurent (entourée en rouge)*

### 1.4 Le système Neuron de Morphosense

Le système Neuron est un système d'instrumentation permettant de mesurer la déformation en 3 dimensions

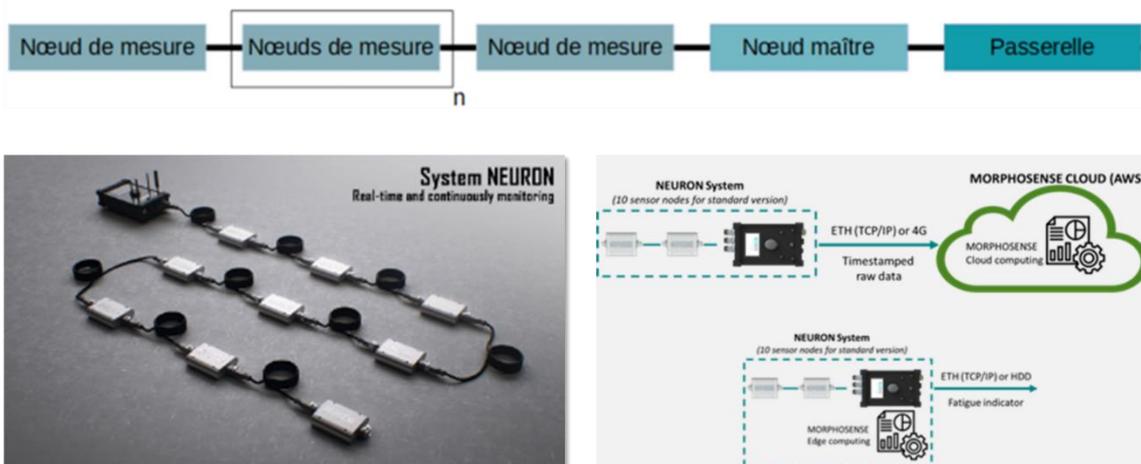
et les vibrations sur 3 axes des structures en temps réel.

Il est composé d'un réseau de capteurs (nœuds de mesure) connectés en série. Chaque nœud de mesure intègre :

- 3 accéléromètres hautes performances MEMS (un pour chaque direction dans l'espace : x, y et z),
- 1 magnétomètre triaxe numérique
- 1 gyromètre triaxe numérique,
- 1 capteur de température.

Ce dernier récolte la température interne de chaque nœud de mesure afin de ré-ajuster les valeurs physiques mesurées en fonction de la température, et permet également de s'assurer de la bonne fonction du nœud de mesure (détection de surchauffe).

Le réseau de nœuds de mesure est interopérable avec un nœud météo permettant d'ajouter au monitoring des données météorologiques. Un schéma simplifié du système est présenté ci-dessous (Figure suivante) :



**Figure 4: Schéma simplifié du système Neuron comportant (n+2) nœuds de mesure reliés en série**

Les nœuds de mesure communiquent par fibre optique avec un nœud dit maître, qui se charge de collecter les données brutes de tous les nœuds pour les envoyer à la passerelle en Ethernet. Une chaîne d'acquisition peut être composée de 1 à 35 nœuds de mesures. La passerelle récolte les données et les stocke dans un fichier. Les données collectées sont ensuite transmises par la passerelle en Ethernet sur un serveur local ou en 4G sur le Cloud en fonction des besoins du client.

Le traitement et la fusion des données récoltées par ce réseau sont ensuite effectués et présentent un moyen efficace et de grande qualité pour la surveillance en temps réel de l'état de santé des structures.

Des tableaux de bord personnalisés sont mis à disposition du client afin de visualiser les indicateurs pertinents de la structure instrumentée.

## 2 Programme de travail

### 2.1 Objectifs et résultats attendus

L'objectif de ce projet est la contribution d'outils d'IA à notre solution d'estimation temps réel de la fatigue et de la durée de vie résiduelle des structures et cela grâce à la détection précoce d'une dérive potentielle. Cette solution nous permettra de proposer à nos clients une solution complète et efficace à la maintenance prédictive et la gestion de risque des structures monitorées.

Les axes de travail définis sont les suivants :

- Création d'une base de données intégrant notamment les sources impactant la structure,
  - Robustification de la base de données via technologies I.A. : clustering et classification,
  - Apprentissage de ces sources : détection automatique et autonome des évènements,
  - Recherche d'anomalies et de signaux faibles en temps réel à la suite de l'apprentissage des sources,
  - Compréhension, interprétation et exploitation de l'anomalie par le Digital Twin de la structure,
  - Estimation/prédiction de l'état structurel futur de la structure,
- Alerte précoce sur les dérives structurelles et identification autonome du problème potentiel.



Figure 5: Tâches du projet

Les résultats attendus du projet sont :

- Création d'une base de données complète sur les sources d'excitation d'une structure, basée sur des données multi-variables synchrones et temps réel, intégrant : accéléromètres, magnétomètres, vent (force et direction), pluie, HR, température et vidéo (statique / dynamique) ;
- Détection automatique de phénomènes non-connus sur la structure ;
- Identification autonome de la source du nouveau phénomène ;
- Alerte précoce sur les dérives potentielles de la structure et maintenance prédictive.

Afin d'atteindre les objectifs définis et de produire les résultats proposés, nous avons découpés le projet en 3 tâches distinctes :

- **Tâche 1. Constitution de la base de données et apprentissage**
  - a. Instrumentation d'une passerelle métallique piétonne avec les instruments listés ci-dessus et récupération en continu et temps-réel des données massives et hétérogènes grâce à l'architecture AXON de Morphosense ;
  - b. Clustering et classification des sources d'évènements (naturelles et « non naturelles ») de la vie « standard » de la structure ;

- c. Apprentissage automatique, par méthode de machine learning, des nouvelles données suites à la base établie précédemment ;
- d. Détection d'anomalies et de signaux faibles pouvant mener à un éventuel défaut structurel / vieillissement accéléré.

- **Tâche 2. Recherche de la cause de l'anomalie**

Utilisation du Digital Twin de la passerelle Saint-Laurent de Grenoble en développement grâce à la mutualisation des activités et des coûts avec le Projet R&D Booster.

Le but pour ce projet étant de connaître la source des nouveaux phénomènes détectés et labéliser ces nouvelles données afin de chercher la cause de l'anomalie. Ce dernier point complètera la base de données.

- **Tâche 3. Maintenance prédictive et amélioration de l'algorithme**

- a. Estimation de l'état futur afin de détecter une dérive potentielle et donc une anomalie ;
- b. Si nécessaire migration de l'algorithme sur des méthodes de deep learning pour améliorer les résultats de prédiction.

Les livrables associés à ces tâches tel que définis lors du montage de projet sont :

- **L1** : Base de données complète alimentée par les données Morphosense intégrant également les mesures de toutes les sources ;
- **L2** : Rapport technique : état de l'art I.A. dédié SHM, résultats des algorithmes d'apprentissage, de détection de nouveaux événements et de prédiction, conclusion sur les résultats obtenus ;
- **L3** : Transfert des connaissances acquises pour de futurs projets en vue de la scalabilité ;
- **L4** : Communication dans revues spécialisés : verrous levés + défis auxquels contribue le projet.

## 2.2 Budget et planning

Le budget total du projet est de 64.12k€ pour une subvention demandée de 32.06k€.

Une partie du budget initial a été mutualisé avec le projet DTPass financé par la région avec le guichet R&D Booster.

Le Projet DTPass intègre l'ensemble des coûts liés au système d'instrumentation, à sa pose, une partie du matériel spécifique et les licences de modélisation 3D.

Le Projet MORPHO-IA financé par la FEREC se focalisant principalement sur l'exploitation des données par des algorithmes d'IA spécifiques.

La figure suivante détaille les budgets initiaux puis validés par la FEREC.

Budget global

(Détailier le budget global en K€)

	Intitulé	Montant (enK€)	
1	Dév. IA et analyse de données	61,56 TTC >> 42 K€TTC (mutualisation des h/mois avec R&D Booster)	
2	Gestion de projet	6,12 TTC	
3	Immobilisation Instrumentation 1 an	6,67 TTC	Poste couvert par R&D Booster
4	Pose et dépose instrumentation	2,92 TTC	Poste couvert par R&D Booster
5	Achat matériel instrumentation	18 TTC >> 10K€ TTC (mutualisation des achats avec R&D Booster)	
6	Licence ANSYS pour modèle 3D	12 TTC	Poste couvert par R&D Booster
7	Exploitation cloud-computing pour IA	6 TTC	

Figure 6: Budget projet

L'instrumentation de la passerelle ayant pris du retard à cause des contraintes du COVID 19, nous n'avons pu démarrer le projet FEREC qu'à partir du mois de mars.

Le projet s'étendra donc avec le même budget de mars 2021 à Mars 2022 selon le planning suivant :

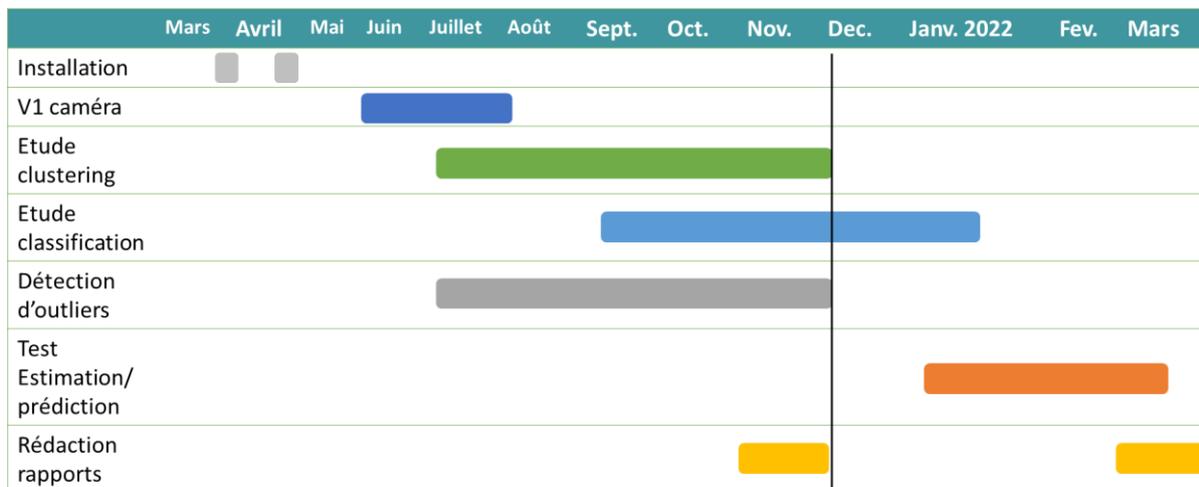


Figure 7: Planning projet

Ce rapport intermédiaire permet de faire une première synthèse des travaux effectués.

Le rapport final de Mars 2022 viendra compléter les résultats techniques et conclura sur notre projet

Chez Morphosense 3 personnes travaillent sur ce projet :

- Anaïs Milhiet (Ingénieure SW),
- Rubal RAVINDER (Alternante en IA),
- Vera SHALAEVA (Experte IA).

### 3 Instrumentation de la Passerelle Saint-Laurent, Grenoble

Les 16 et 17 mars 2021, le système Neuron de Morphosense a été installé sur le pont Saint-Laurent à Grenoble (Figure 3). Il contient la dernière version (V3) de passerelle développée. Il est également composé d'un nœud interopérable auquel est relié une station météo. En complément, une caméra a été installée. La station météo et la caméra permettent de récolter des données complémentaires au système qui vont permettre de faciliter notre étude. Le système est donc composé d'un nœud météo, d'une caméra et de 19 nœuds de mesure.



*Figure 8 : Fixation de la station météo, de la caméra de comptage et des nœuds de mesure sur les haubans.*

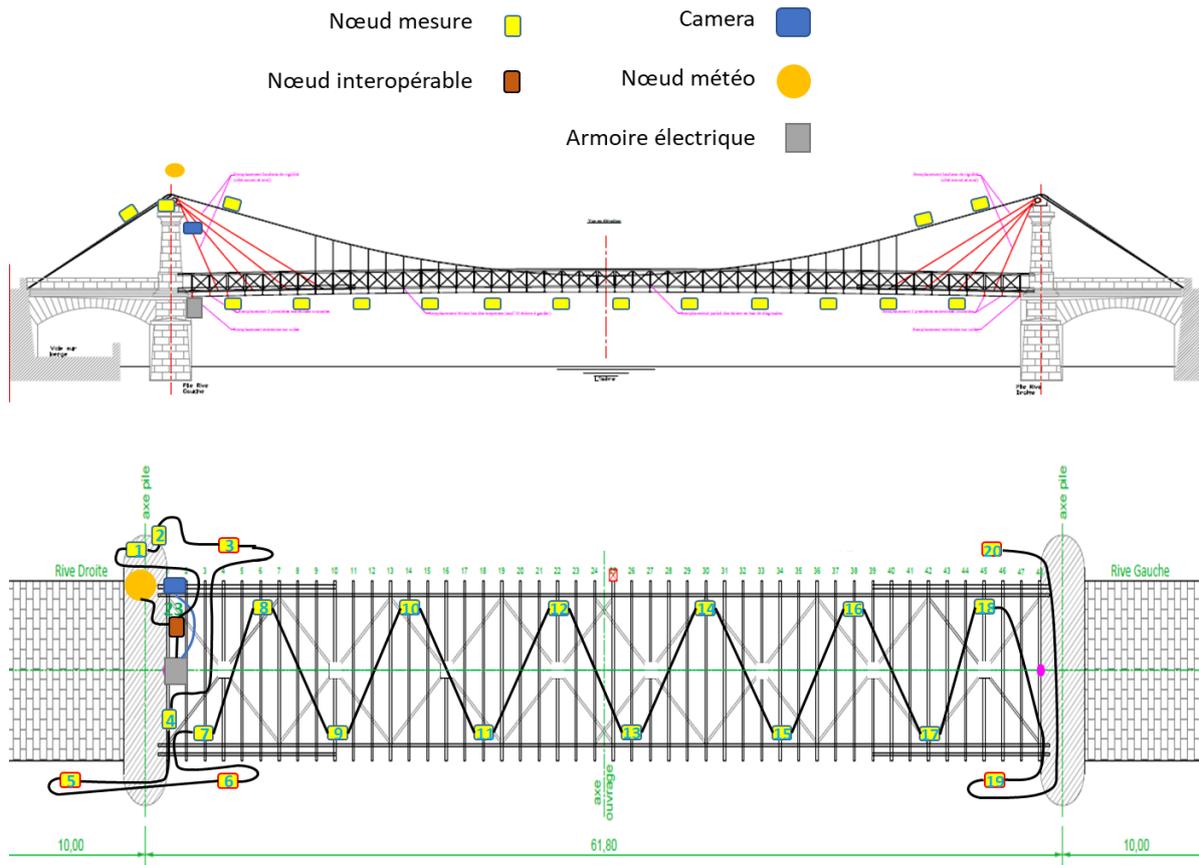
Chaque nœud de mesure contient un accéléromètre 3-axes de pointe permettant de calculer les inclinaisons en chaque point de mesure ainsi que les vibrations ambiantes. Ces vibrations contiennent l'information sur les fréquences propres de l'ouvrage et ont un fort impact dans la validation du DT.

La caméra a été installée sur la passerelle Saint-Laurent en complément du système d'acquisition pour deux raisons :

- la labélisation des données pour tenter de simplifier l'application des méthodes d'apprentissage automatique,
- la position des piétons et vélo sur la passerelle pour la partie DT.

Les données étant temporelles, sans les informations annexes provenant de cette caméra et de la station météo, il peut être très difficile de retrouver la source d'un évènement seulement avec les données accélérométriques des nœuds de mesure « classiques ». De plus, l'apport d'informations complémentaires peut permettre d'appliquer des algorithmes d'intelligence artificielle (supervisés ou non-supervisés) en vue d'une meilleure surveillance de l'ouvrage.

Une vue d'ensemble du positionnement des composantes du système sur le pont Saint-Laurent est présentée sur la figure suivante.



**Figure 9 : Vue d'ensemble du positionnement des composants du système Neuron sur la passerelle Saint-Laurent, Grenoble**

Le système se compose de :

- 11 nœuds de mesure placés sous le tablier
- 3 nœuds sur la pile de la rive droite
- 5 nœuds de mesure sur les câbles
- 1 nœud de mesure permet de communiquer les informations de la station météo.
- Une caméra placée sur la rive droite, sur le même pilier que la station météo.

L'acquisition en continu des données a été lancée le 16 mars 2021 suite à l'installation des nœuds de mesure, de la caméra et de l'armoire électrique. Le lendemain, elle fut interrompue pour continuer avec la mise en place du reste du système, puis relancée avec le système complet à la fin de cette deuxième journée.

La fréquence d'acquisition du système a été paramétrée plusieurs fois dans le but d'effectuer des tests sur la plage de fréquences modales de la structure à considérer. Cette mesure, utile pour suivre le comportement statique et dynamique de la structure, permet donc d'analyser les fréquences propres de la structure, qui vont des basses fréquences (proches de 0 Hz) pour la « fondamentale » aux hautes fréquences pour les « harmoniques » (dépendant de la structure considérée). La plage de fréquence modales observables augmente avec la fréquence d'acquisition.

Les premières fréquences modales du tablier et des haubans de la passerelle Saint-Laurent se situent en-dessous de 10 Hz. Une fréquence de 40 Hz avait initialement été choisie. Elle a par la suite été redéfinie à 100 Hz pour une analyse plus fine de la structure.

## 4 Données récoltées par le système Neuron sur la Passerelle Saint-Laurent

### 4.1 Caméra

Les images récoltées par la caméra sont envoyées directement sur la plateforme Cloud Morphosense. Il a été décidé que les images prises soient de bonnes qualités et toutes les 0.5 secondes afin de :

- Effectuer tous les tests possibles pour la détection de piétons sans être restreints par la qualité des images.
- Identifier les piétons et les cyclistes qui traverseraient rapidement la passerelle.

Le temps de prise des images et leur qualité seront sûrement réduits suites aux études menées afin d'optimiser toute la chaîne. Un exemple d'image capturée par la caméra du système est présenté sur la **Figure 5**. L'image « brute » a une taille de 3072 x 2048 pixels.



*Figure 10: Exemple d'image capturée par la caméra sur la passerelle Saint-Laurent*

Les visages des éventuels personnes présentes sur les images sont floutées a posteriori afin de respecter les normes RGPD.

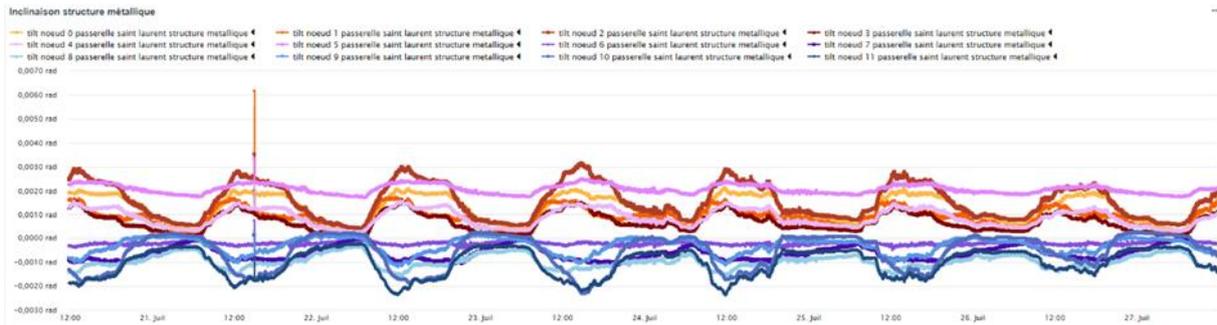
Ces images sont par la suite traitées et utilisées dans le cadre des études de labélisation du nombre de piétons sur la passerelle et de leur position à un temps donné.

### 4.2 Nœuds de mesure du système Neuron

Les données brutes acquises par les nœuds de mesure du système sont remontées sur le Cloud de Morphosense. Des calculs sont appliqués dessus pour ensuite rendre ces données utilisables. Elles sont ensuite disponibles en temps réel sur un tableau de bord qui est mis à jour toutes les cinq minutes. Plusieurs informations sont extraites de ces données et visualisées sur le tableau de bord. En voici quelques exemples :

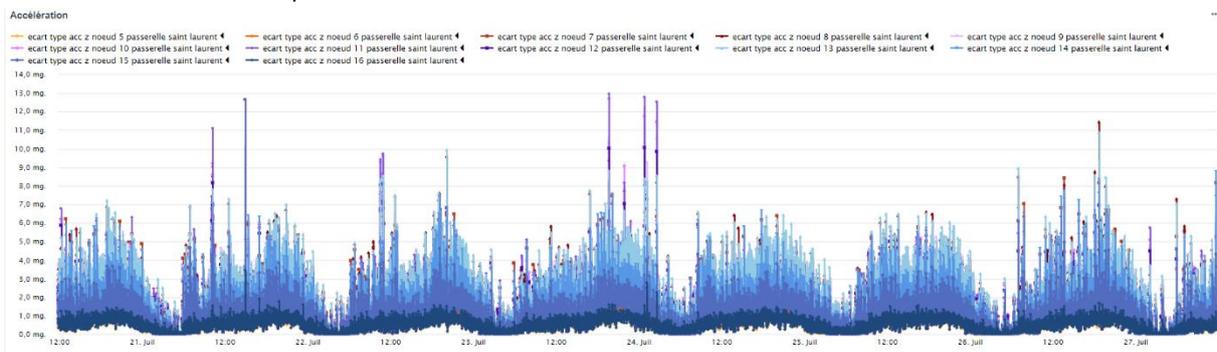
- **Les données brutes :**

- Inclinaisons des nœuds de mesure (Figure 11) : les nœuds pairs et impairs étant placés de part et d'autres du tablier, on observe une symétrie dans l'inclinaison du tablier.



*Figure 11 : Exemple de visualisation de l'inclinaison des nœuds du tablier*

- Accélération selon l'axe x, y ou z des nœuds de mesure (Figure 12) : les accélérations varient selon la position des nœuds sur le tablier du pont. Les nœuds aux extrémités (proches des piliers) semblent moins vibrer que ceux au centre.



*Figure 12 : Exemple de visualisation de l'écart type des accélérations en z des nœuds du tablier*

- **Les données calculées à partir des données brutes :**

- Déformation maximale de la structure en un point (Figure 13) : la structure se déforme plus en journée que de nuit, et présente des variations cycliques.



*Figure 13 : Exemple de visualisation de la déformation maximale du tablier en un point*

- Suivi des fréquences modales de la structure (Figure 14) : l'analyse des fréquences propres à la structure donne une indication sur son état de santé. Des fréquences constantes dans le temps sont le signe d'une structure en bon état.

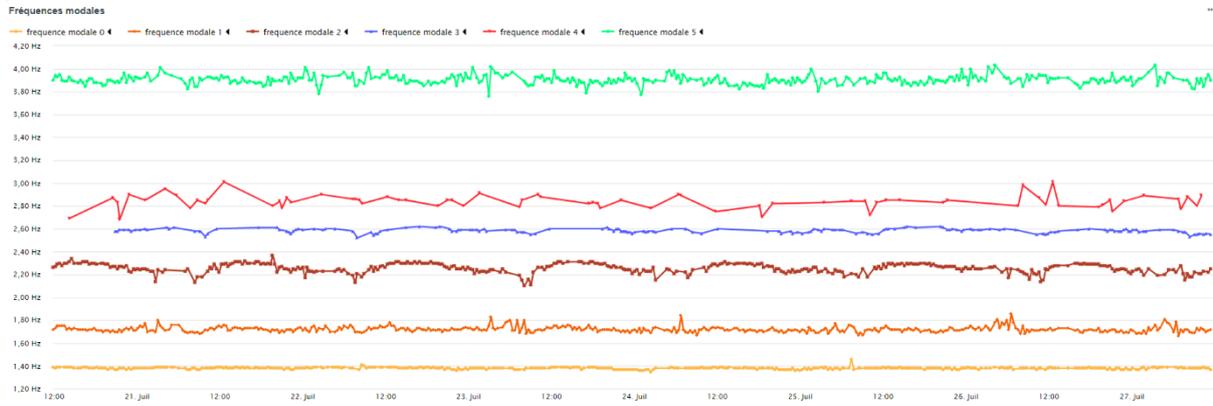


Figure 14 : Exemple de visualisation du suivi des fréquences modales de la structure

Selon l'infrastructure, d'autres indicateurs plus ou moins techniques peuvent être calculés et visualisés. L'objectif ici était de montrer un exemple de surveillance qui peut être réalisé sur une structure en temps réel.

### 4.3 Station météo

Les données collectées par la station météo sont d'ordre météorologiques : température ambiante, vitesse du vent, intensité de pluie ou de grêle, pression atmosphérique et humidité relative. Comme pour les nœuds de mesure, ces données sont collectées par le nœud maître du système et les informations sont traitées en série temporelle.

Des problèmes d'acquisition de la station météo ont été constatés par moment. La Figure 15 présente une visualisation sur le tableau de bord du type d'anomalie rencontré : sur le graphique, une constante est observée (à partir du 21 juillet 2021) pour la température ambiante (en jaune) et la vitesse du vent (en orange). La station météo a donc dû être remplacée afin de palier à ce problème.

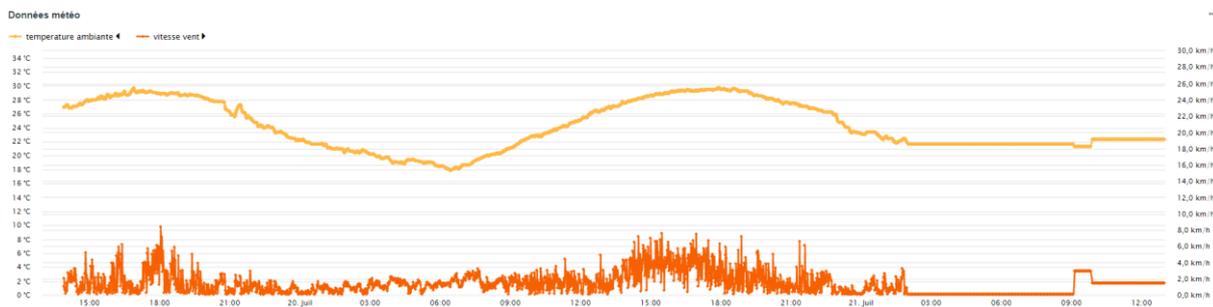


Figure 15 : Exemple de visualisation des données provenant de la station météo avant son remplacement

## 5 Quelques notions d'IA

L'IA est un vaste domaine regroupant les machines ou les programmes capables de simuler artificiellement le raisonnement humain. C'est un domaine qui connaît une forte expansion notamment depuis l'explosion de l'utilisation d'Internet. Il regroupe le sous-domaine nommé « apprentissage automatique » (« machine learning » en anglais), qui

lui-même intègre l'apprentissage profond (« deep learning » en anglais).

L'apprentissage automatique et profond consistent à faire « apprendre » une tâche à une machine à partir de données sans explicitement être guidée par l'Homme, c'est-à-dire de donner la capacité à la machine d'améliorer ses performances à résoudre les tâches sans être explicitement programmée pour chacune d'entre elles. Les tâches peuvent relever de la régression, de la classification ou encore du clustering.

L'algorithme est d'abord entraîné sur des données d'apprentissage afin de paramétrer ses équations (l'intérêt de cette phase est d'obtenir des équations le plus généralisables possibles). Ensuite, il est évalué sur un jeu de données de test (qu'on ne lui aura jamais présenté auparavant, et qui est donc nouveau dessus). Pour chaque observation du jeu de données, il émet une prédiction (calculée d'après ses équations optimisées). Si la précision de l'algorithme est suffisante pour la tâche demandée, il est enfin implémenté et utilisé sur de réels jeux de données.

Par exemple, un algorithme peut servir à différencier des images d'animaux. Il s'agirait alors d'une problématique de classification. Le jeu de données d'entraînement comporterait dans ce cas des images de chats, de poules, de crocodiles etc. qui sont annotées. La phase de test consisterait à évaluer si l'algorithme prédit bien la classe de chaque animal.

On distingue plusieurs types d'algorithmes :

- Ceux d'apprentissage automatique : ils sont basés sur des approches mathématiques et statistiques. Ils « apprennent » sur des ensembles de données structurés grâce à l'Homme ;
- Ceux d'apprentissage profond : on parle souvent de réseaux de neurones. Ils « apprennent » sans être guidés par l'Homme et sont basés sur des méthodes bien plus complexes combinant différents algorithmes en s'inspirant du cerveau humain (fonctionnement d'un neurone plus précisément). Ces systèmes sont capables de travailler sur des données non-structurées pour identifier eux-mêmes les caractéristiques discriminantes.

Les réseaux de neurones peuvent se montrer bien plus performant que les algorithmes d'apprentissage automatique. En contrepartie, ils sont plus gourmands en données et en énergie. Ainsi, ils sont souvent utilisés pour des tâches plus complexes. Dans notre projet, ils ont été utilisés pour le traitement des images.

## **6 Résultats de l'étude de la Passerelle Saint-Laurent**

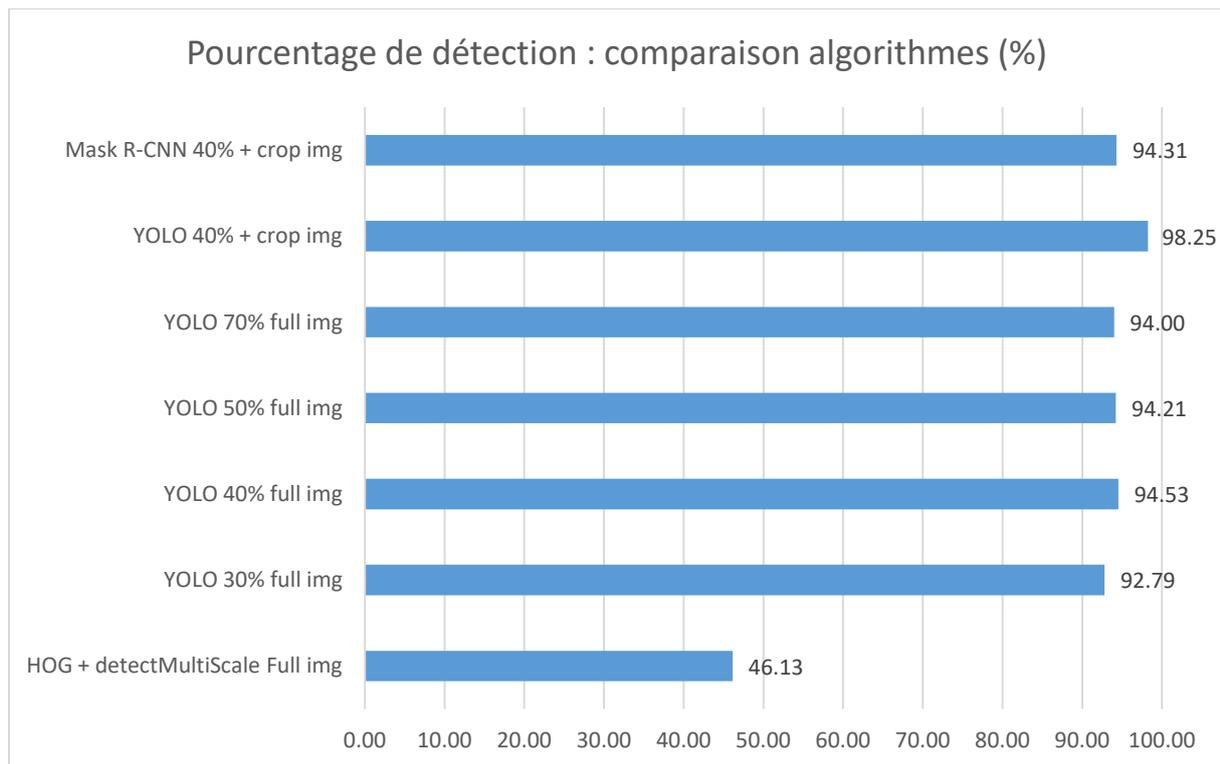
### **6.1 Détection de piétons**

Comme indiqué dans la partie 4.1., quelques pré-traitements ont été réalisés sur les images récoltées par la caméra afin que la détection de piétons fonctionne au mieux et soit la plus efficace :

- a) Rotation de l'image de -90 degrés pour remettre les piétons dans le sens de la gravité,
- b) Réduction et rognage de l'image pour :
  - a. Faciliter son traitement,
  - b. Retirer les piétons se trouvant du côté opposé du pont (mal définis sur l'image, difficiles à détecter),
  - c. Que la taille des piétons sur l'image corresponde à celle des piétons dans les bases d'apprentissage (cette opération n'est pas nécessaire car en temps normal, du scaling est appliqué).
- c) Ordonnement des images pour qu'elles soient traitées par ordre d'arrivée.

Différents algorithmes d'apprentissage profond de détection de piétons ont été testés en accord avec les méthodes présentes dans l'état de l'art : HOG associé à cascade classifieur, YOLO et Mask R-CNN. Différentes tailles d'images, rognées ou non, ont été comparées sur les modèles les plus efficaces pour optimiser la détection.

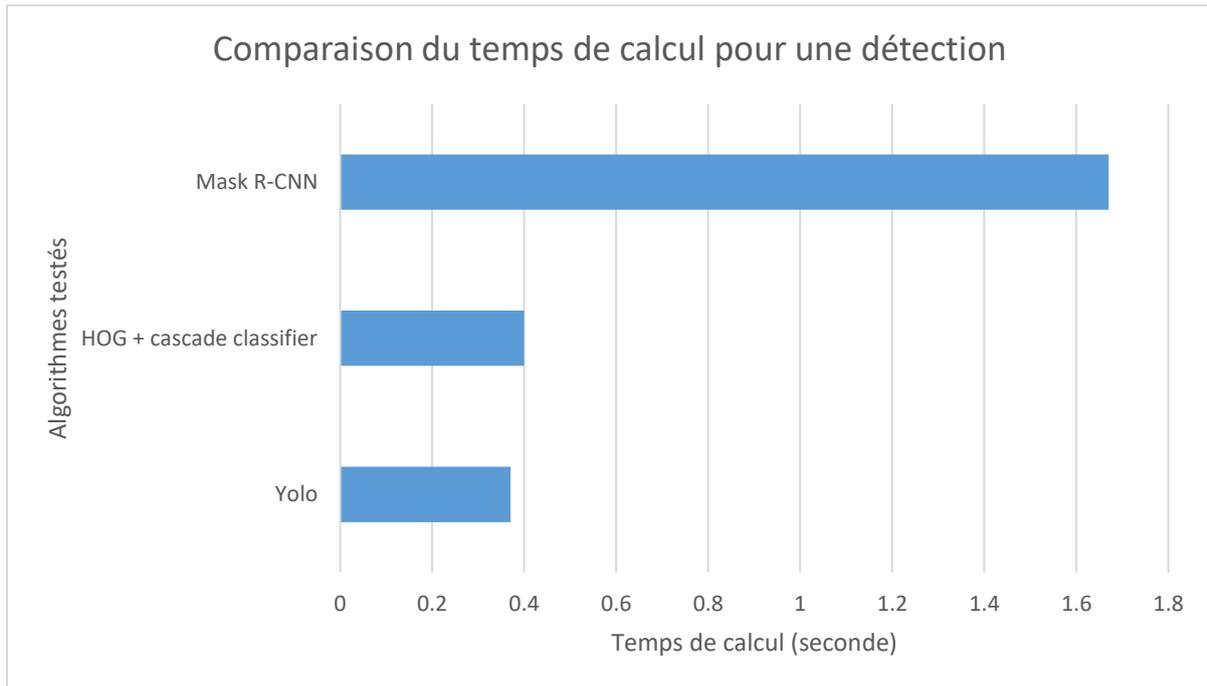
Le comparatif des pourcentages de détection obtenus avec les différentes méthodes est présenté sur la Figure 16. Les résultats de détection des algorithmes ont été comparés à ceux d'un comptage manuel pour estimer le pourcentage de détection des piétons.



**Figure 16 : Comparaison des pourcentages de détection d'algorithmes de détection de piétons selon la taille des images données en entrée**

On remarque assez rapidement que les algorithmes Mask-RCNN et YOLO présentent d'excellents résultats quelle que soit la taille de l'image et son éventuel rognage. Ils détectent plus de 90 % des piétons présents sur la passerelle à un temps donné.

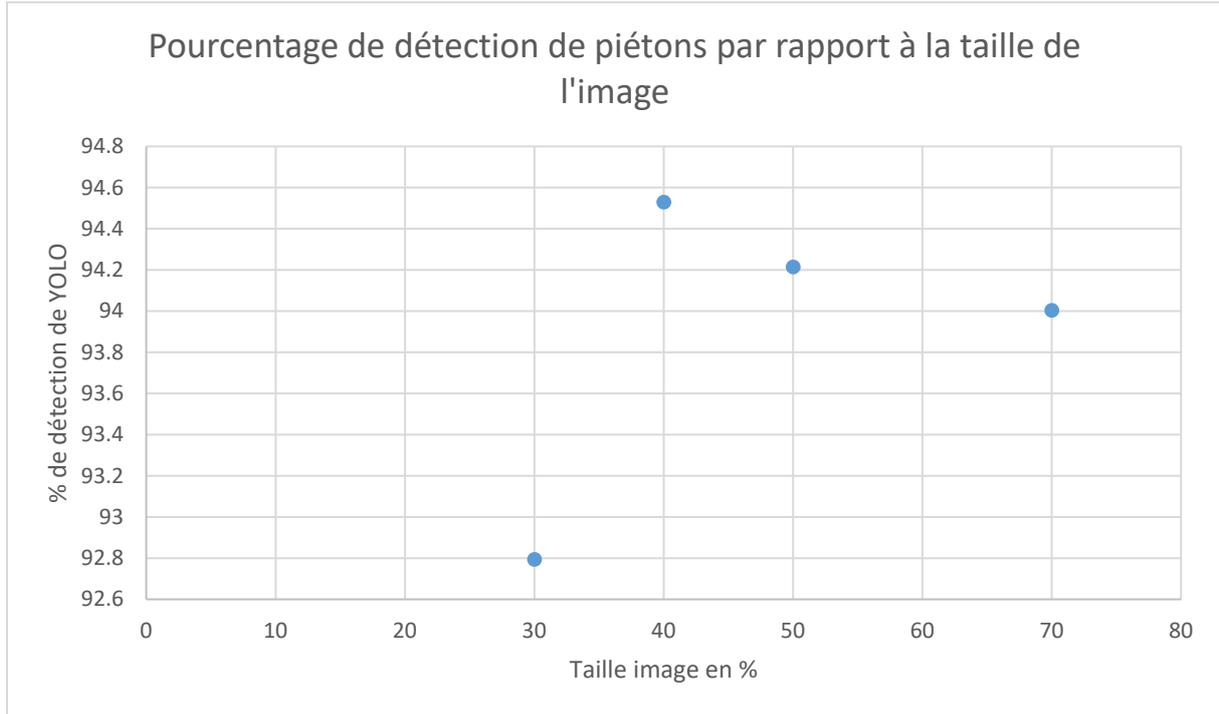
Les temps de calcul de chaque algorithme ont ensuite été comparés en vue de leur future implémentation pour le traitement d'images en temps réel (Figure 17).



*Figure 17 : Comparaison du temps de calcul pour une détection des algorithmes*

L'algorithme YOLO, en plus de son excellente détection présente un temps de calcul quatre fois inférieur à celui de l'algorithme Mask-RCNN. C'est donc cet algorithme qui a été choisi.

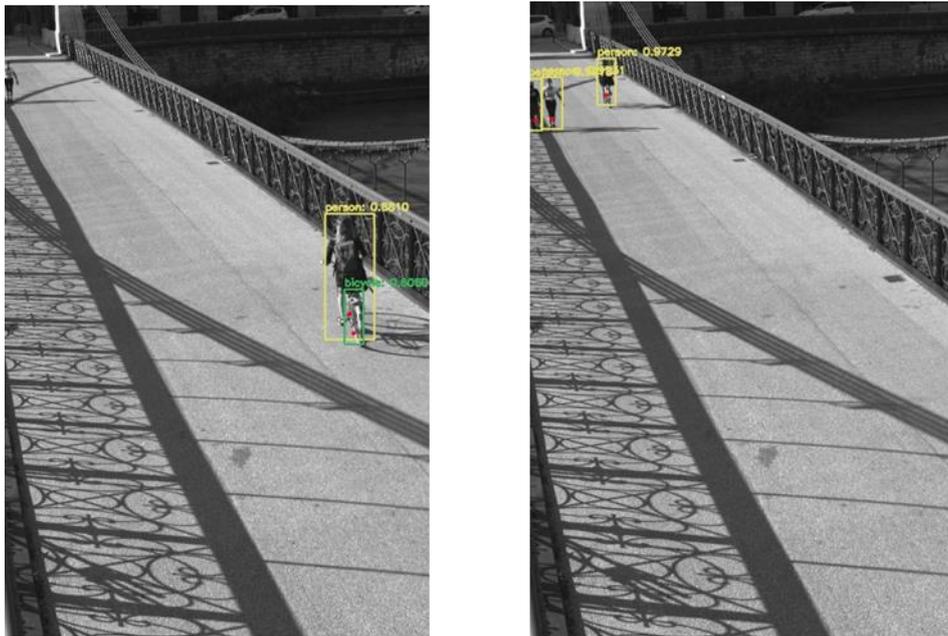
L'algorithme pré-entraîné a été importé depuis une librairie de traitement d'images (OpenCV, ressource regroupant des algorithmes et des méthodes de traitement d'image) et a été utilisé pour une troisième étude. Cette dernière a été réalisée pour trouver la taille optimum des images permettant une meilleure détection et un temps de calcul réduit. Quatre tailles d'images (en pourcentage par rapport à la taille avant pré-traitement) ont été testées. Les résultats sont présentés dans la figure suivante :



*Figure 18 : Comparaison du pourcentage de détection de l'algorithme YOLO par rapport à la taille des images*

La taille des images retenue est donc de 819x1228 pixels. Le temps de traitement d'une image est d'environ 0,28 secondes. Avec tous ces pré-traitements, on obtient un score de 98.25% de détection des piétons et cyclistes en comparaison avec une labélisation manuelle.

Ci-dessous un exemple de détection sur deux images différentes avec l'algorithme YOLO (à gauche pour la détection de cycliste et à droite pour celle de piétons). En jaune et vert figurent les zones de détection accompagnées du label prédit et du pourcentage de confiance de l'algorithme sur la prédiction.



*Figure 19: Exemple de détection par YOLO de cyclistes(gauche) et de piétons (droite)*

D'autres comparaisons des performances de l'algorithme YOLO ont été réalisées pour s'assurer de l'efficacité du modèle ; en particulier le nombre d'objet à détecter (image de gauche) ou taille des objets à détecter (image de droite) ont été étudiés.

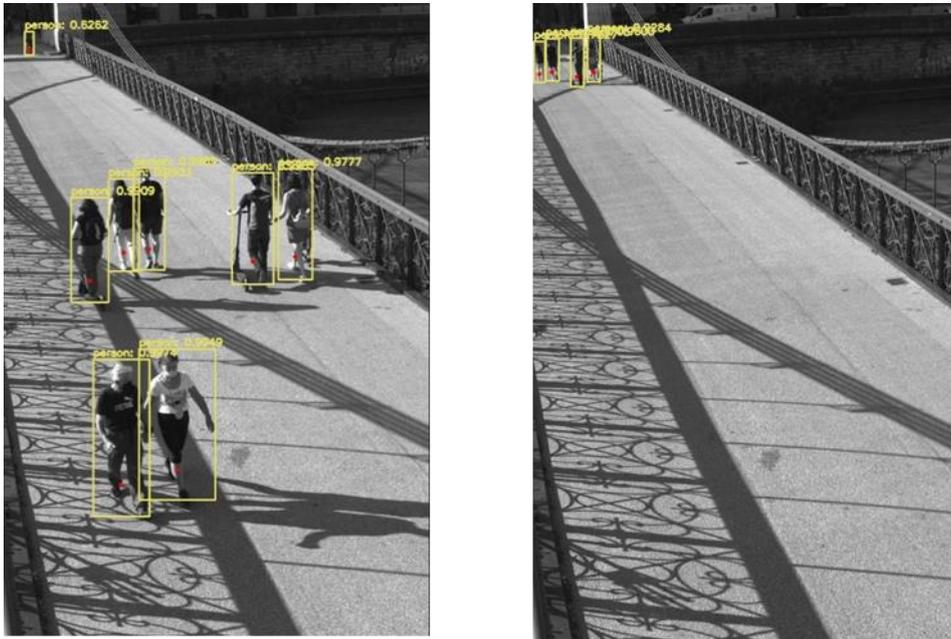


Figure 20 : Détection multiple objets avec YOLO

On remarque que l'algorithme semble assez puissant. Très peu de personnes ne sont pas détectées : principalement celles en haut de l'image (très petite et mal définies) et celles sur le bord gauche ou bas car elles peuvent être coupées. La présence de groupes de personnes ne semble pas réduire la capacité de prédiction de l'algorithme, qui semble bien différencier chaque 'objet' de l'image.

Cette détection automatique de piétons a pour but de sortir deux types de résultats pour le DT et sa partie modélisation :

- Connaître le nombre de piétons à un temps donné afin d'en juger la charge totale présente sur la structure,
- Connaître la position de ces piétons afin de pouvoir appliquer des charges ponctuelles sur la structure.

Une calibration à l'aide d'un échiquier va donc être réalisée afin d'étalonner l'image et de pouvoir convertir les pixels en distance réelle.

## 6.2 Détection d'outliers

Les données récoltées par le système Neuron contiennent de nombreuses informations sur le fonctionnement naturel de la passerelle mais aussi des données aberrantes dues au système d'acquisition ou plus rarement à un problème de santé de la structure. Des algorithmes spécialisés dans la détection d'anomalies/nouveautés (outliers) sont donc appliqués sur les données récoltées afin de détecter automatiquement ces points atypiques. Il existe deux types d'algorithmes :

- Ceux qui prennent une tranche de signal et effectue une détection sans à priori,
- Ceux qui apprennent le comportement sur une première tranche de données puis qui font une détection des outliers avec l'à-priori des données apprises.

Un grand nombre d'algorithmes ont été développés pour détecter les anomalies sur des jeux de données car leur champ d'application est très vaste. L'utilisation de l'algorithme DBSCAN, appartenant à la première classe décrite, semble approprié à notre cas d'usage. Il a donc été testé sur un mois de données d'accélération recueillies par les capteurs, et plus particulièrement sur leur écart-type. La Figure ci-dessous permet de visualiser les outliers détectés par l'algorithme DBSCAN.



**Figure 21: Visualisation du résultat de détection d'outlier de l'algorithme DBSCAN sur un mois de données et sur 4 nœuds de mesure**

Les données considérées comme standard sont en violet et les données considérées comme outliers sont en bleu. Certains outliers, labélisées « R », sont causés par les redémarrages du système. L'outlier labélisé « S » vient, lui, d'un test volontaire réalisé sur la passerelle (saut de deux personnes). En ce qui concerne les outliers non-labélisés, leur cause n'est pas encore connue (utilisation du DT dans ce but). Certains d'entre eux sont généraux (phénomène visible sur tous les nœuds de mesure) tandis que d'autres semblent appartenir à des phénomènes plus locaux sur la passerelle (visibles seulement sur certains nœuds de mesure).

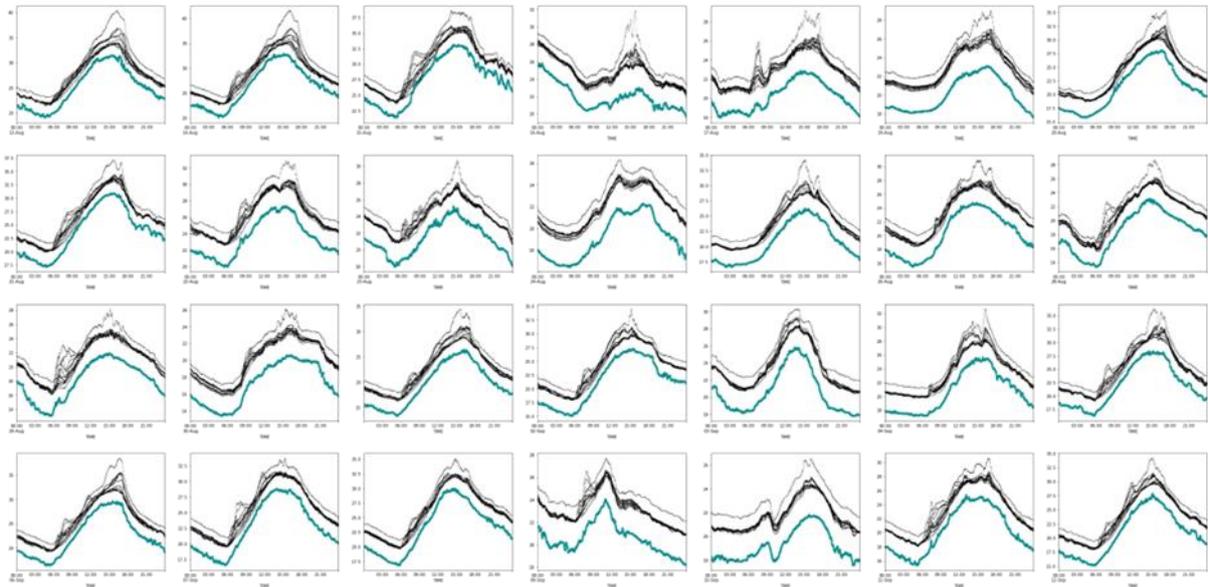
L'algorithme DBSCAN semble assez efficace quand les anomalies ont plus ou moins un ordre de grandeur de plus que le reste des observations (Figure 18 en haut à gauche). Pour les 3 autres sous-graphes, on pourrait se poser la question de la frontière choisie par l'algorithme pour délimiter le « normal » de l'anomalie. D'autres algorithmes pourraient être testés par comparaison. Nous serions cependant confrontés au même problème de délimitation. Une étude avec des données entièrement labélisées serait une piste à envisager pour aider à répondre à cette question.

### 6.3 Détection de nouveautés

#### 6.3.1 Prédiction de la température ambiante en fonction des températures internes des nœuds de mesure

Comme mentionné précédemment (partie 4.3.), des problèmes d'acquisition de données avec la station météo ont été rencontrés. Sur cette plage de temps, il a donc été difficile de pouvoir étudier l'impact de la température sur la déformation et les vibrations de la structure.

Pour tenter de pallier à ce problème, une étude comparant les températures internes des nœuds du système avec la température ambiante a été réalisée. La Figure 22 comporte un ensemble de graphiques où chaque sous-graphe représente les températures internes des 12 nœuds du tablier (en noir) et la température ambiante (en turquoise) pour une journée entière.

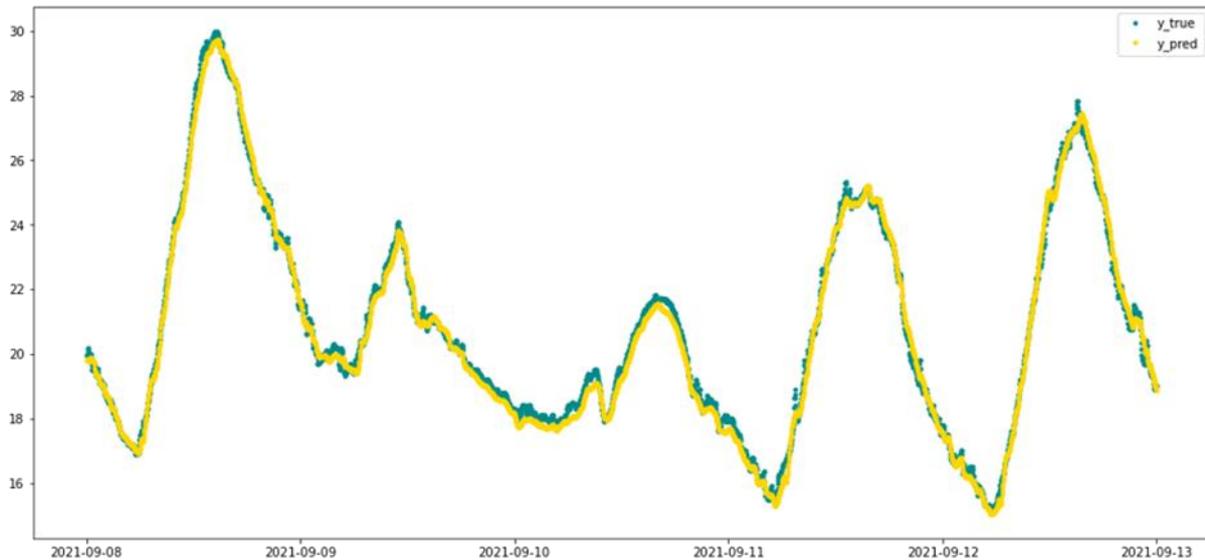


*Figure 22: Superposition entre les températures internes des nœuds du tablier (noir) et la température ambiante (turquoise) pour chaque jour sur 28 jours de données*

Bien que les valeurs de température au sein des boîtiers soient bien supérieures à celle de la température ambiante, les deux courbes suivent bien le même phénomène.

Il a donc été envisagé de prédire grâce à un algorithme la température ambiante à partir des températures internes des nœuds pour pouvoir continuer les études en cours. Seuls les nœuds de la structure métallique (tablier) ont été choisis. Une régression linéaire a ainsi été appliquée afin d'apprendre le comportement des températures internes et d'en déduire la température externe. L'algorithme est précis à 0.20°C (calcul de l'erreur de l'algorithme effectué sur une plage de données où la station météo fournissait des données) tandis que la température varie d'environ 10°C sur une journée, ce qui est largement suffisant pour pouvoir utiliser les prédictions pour nos études.

La Figure suivante présente les résultats de l'algorithme de prédiction sur 5 jours de données. En turquoise sont visualisées les « vraies » valeurs de température ambiante et en jaune les valeurs prédites par l'algorithme d'apprentissage automatique.



*Figure 23 : Exemple de prédiction de la température ambiante en fonction des températures internes des nœuds de mesure du tablier*

Graphiquement, la différence entre la courbe de la « vraie » température et celle prédite est négligeable. Les deux courbes se superposent. Cela permet d'affirmer que pour notre cas, l'algorithme peut être implémenté et véritablement utilisé pour prédire des températures sur des plages où la station météo ne fonctionnait pas.

### **6.3.2 Etude de l'impact de la température sur les variations de la structure pour la détection d'anomalie**

Le pont Saint-Laurent est principalement excité par les piétons et cyclistes (déformation dynamique). En ce qui concerne la déformation statique, les piétons n'effectuant pas une grosse charge ponctuelle, c'est principalement la température qui influe sur la déformation de la structure et donc sa flèche par exemple.

Une étude a donc été réalisée pour pouvoir tenter d'estimer la flèche de la structure en fonction de la température. Le but de cette étude serait de pouvoir comparer les prédictions de la flèche (grâce à l'algorithme d'apprentissage automatique) avec les « vraies » valeurs de flèche (calculées par les indicateurs du système) afin d'observer une éventuelle divergence, et donc alerter sur l'apparition d'une éventuelle anomalie ou d'un phénomène. Ce serait le rôle du DT de tenter d'expliquer le phénomène qui se produit.

La Figure 24 représente visuellement la corrélation entre d'une part la flèche (en violet) et d'autre part la température ambiante (en vert) ou la température interne de la station météo (en orange).

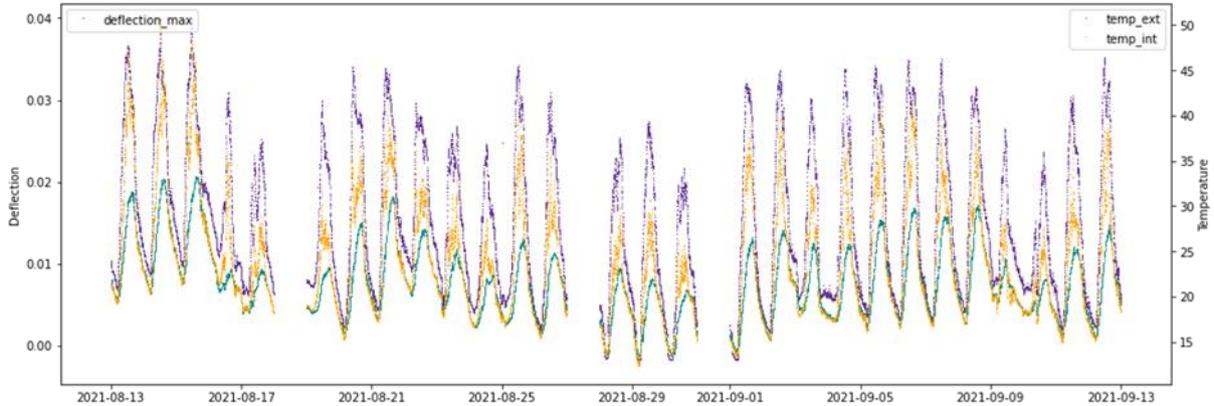


Figure 24 : Comparaison de la déformée maximale en un point de la structure par rapport aux températures internes et externes de la station météo

Une régression polynomiale d'ordre 2 (algorithme d'apprentissage supervisé) a été utilisée afin d'effectuer la prédiction de déformation en fonction de la température. Plusieurs modèles prenant en entrée différentes températures ont été comparés : température interne de la station météo, des nœuds de mesure du tablier ou des câbles, ou encore température ambiante. Des précisions moyennes oscillant entre 1 cm et 0,6 cm ont été obtenues. La flèche de la structure variant de quelques centimètres lors du fonctionnement standard, une précision de l'ordre du centimètre peut sembler suffisant avec une seule entrée (la température). Pour améliorer la précision de l'algorithme, d'autres données pertinentes doivent être ajoutées en entrée du modèle.

Ci-dessous un graphique comparant les prédictions obtenues avec un modèle basique avec les « vraies » valeurs de flèche sur 6 jours de données. En turquoise sont représentées les « vraies » valeurs de la déformée, calculées par les algorithmes Morphosense, et en jaune les valeurs prédites par l'algorithme d'apprentissage automatique.

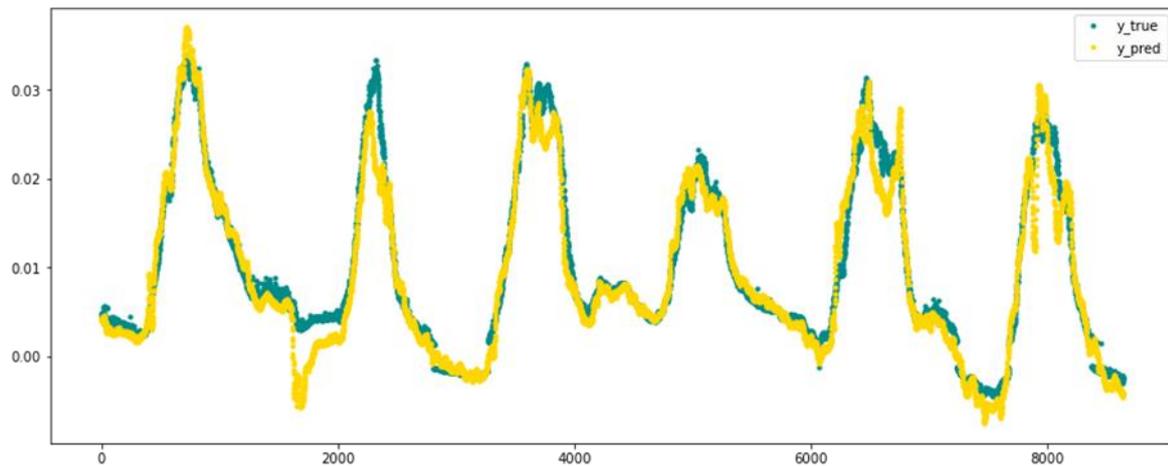


Figure 25: Comparaison entre les "vraies" valeurs de flèche et celles prédites par l'algorithme d'apprentissage automatique sur 6 jours de données

L'algorithme semble plutôt bien prédire les tendances générales. Toutefois, il ne suit pas très bien les petites variations (notamment les pics de journée). Cela démontre que seule la température ne peut pas expliquer à elle seule la déformation de la structure. Le modèle d'apprentissage automatique est donc en cours d'amélioration.

## 6.4 Labélisation des événements présents dans les séries temporelles

### 6.4.1 Effet des conditions météorologiques sur la passerelle

Une étude portant sur l'effet des conditions météorologiques sur les données d'accélération a été réalisée pour les nœuds du tablier et ceux des câbles. Elle semble non-concluante pour les nœuds du tablier sur un mois de données en été. Des données sur plusieurs mois de l'année sont nécessaires pour attester de l'impact de la température (par exemple) sur l'accélération des nœuds de mesure de la structure métallique. En revanche, l'étude semble montrer une corrélation de l'accélération des nœuds des câbles avec la température et la vitesse du vent. La Figure 26 présente 3 graphiques en fonction du temps : en haut, une superposition de la vitesse du vent (en noir) avec l'écart-type des accélérations des nœuds des câbles (5 nuances de bleu) ; au milieu, seulement l'écart-type des accélérations des nœuds des câbles (nuances de bleu) ; en bas, la vitesse du vent (en noir).

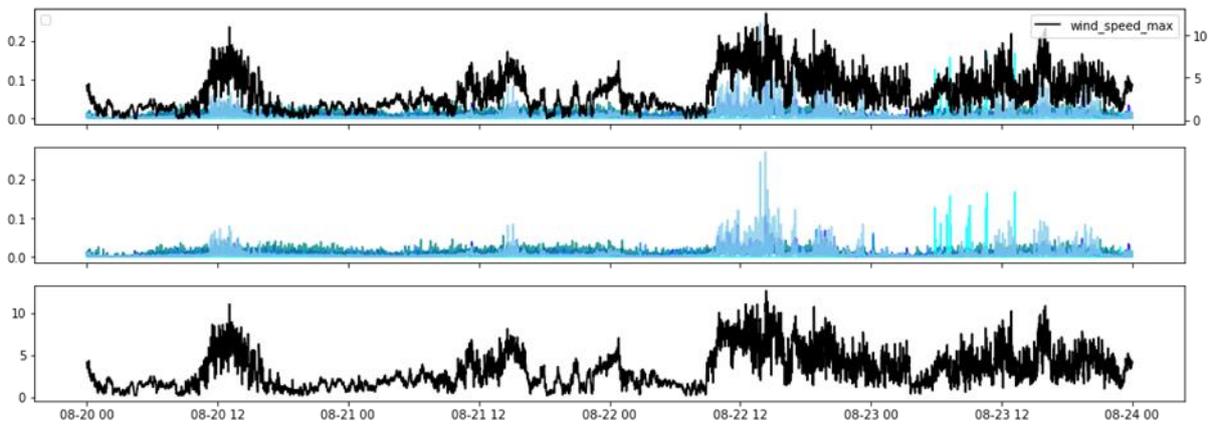


Figure 26: Visualisation de la corrélation entre l'écart-type des accélérations des nœuds des câbles et la vitesse du vent

On observe que les courbes semblent se suivre. La corrélation de l'accélération des câbles avec la température reste moins sûre car ces deux courbes suivent la saisonnalité jour/nuit. Ces hypothèses sont en cours d'étude et sont toutefois à confirmer.

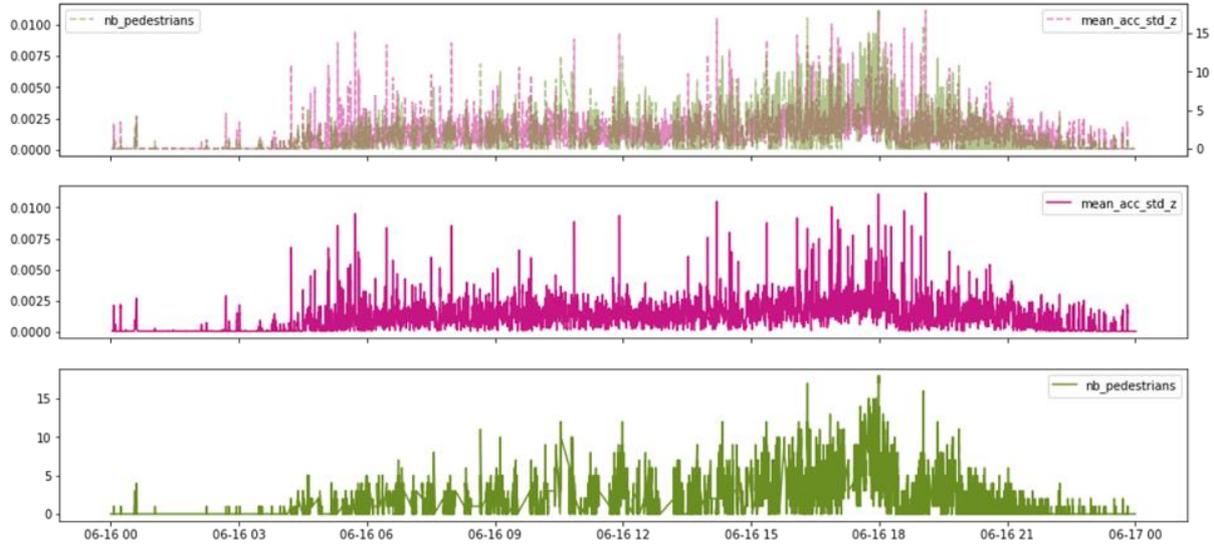
Une autre étude portant sur l'effet des conditions météorologiques sur la déformation maximale de la structure métallique est également en cours. En accord avec les études précédentes (partie 5.3.2.), la température est la composante météorologique qui semble le plus influencer sur la flèche. L'humidité semblerait inversement corrélée, ce qui reste à démontrer.

### 6.4.2 Effet des piétons sur l'accélération

Grâce à l'installation de la station météo et à l'algorithme de détection de piétons qui fonctionnent en temps réel, des événements pourraient être placés sur l'accélération observée à un temps  $t$ . Similairement à l'étude reliant la température avec la flèche (partie 5.3.2.), cela permettrait de repérer d'éventuelles anomalies.

Pour ce faire, nous avons d'abord vérifié si l'accélération et le nombre de piétons sur la passerelle à un temps  $t$  sont bien corrélés, *i.e.* si ce sont bien les piétons qui excitent la structure. La Figure 27 comporte 3 graphiques en fonction du temps : en haut, la moyenne de l'écart-type des accélérations des nœuds de la structure métallique (en rose) superposée avec le nombre de piétons détectés par l'algorithme YOLO (partie 5.1., en vert) ; au milieu, la moyenne de l'écart-type des accélérations des nœuds de la structure métallique (en rose) ; en bas, le nombre de piétons

détectés par l'algorithme YOLO (en vert).



*Figure 27 : Visualisation de la corrélation entre la moyenne de l'écart-type des accélérations des nœuds de la structure métallique avec le nombre de piétons détectés sur la passerelle*

La moyenne de l'écart-type des accélérations a été prise plutôt que les 12 mesures individuelles pour faciliter la lecture du graphique. Il semblerait que les deux phénomènes soient effectivement liés. Un coefficient de 0,53 relierait les deux variables d'après la matrice de corrélation (corrélation de Pearson).

La mise en place d'un algorithme prenant en entrée le nombre de piétons pour prédire la déformation ou la vibration de la structure est en cours de réflexion.

## 7 Conclusion

A l'heure actuelle, les 19 capteurs installés sur la passerelle Saint-Laurent à Grenoble sont fonctionnels et sont une grande source de données pour le projet MORPHO-IA. Plusieurs algorithmes d'apprentissage automatique et d'apprentissage profond ont d'ores et déjà pu être implémentés pour différents usages :

- Détection du nombre de piétons et leur position sur la passerelle à un temps donné par YOLO ;
- Détection d'outliers dans les séries temporelles de données par DBSCAN ;
- Prédiction de la température ambiante à partir des températures internes des capteurs par régression linéaire.

Les études suivantes sont en cours :

- Prédiction de la déformation de la structure en fonction de la température et d'éventuelles autres données ;
- Effet des conditions météorologiques sur la déformation et les vibrations de la structure ;
- Utilisation du nombre de piétons prédits par YOLO comme entrée dans d'autres algorithmes ;
- Détection automatique d'anomalies et de nouveauté dans les signaux reçus par les capteurs.

Le DT est pour sa part en cours de déploiement par Morphosense.

Références

- [1]  
Sétra, Guide méthodologie : "Passerelles piétonnes - Evaluation du comportement vibratoire sous l'action des piétons", 2006.
- [2]  
HIVOSS, Guide de dimensionnement : "Vibrations des passerelles piétonnes", 2008.
- [3]  
S. S. Law, Z. M. Wu et S. L. Chan, «Vibration control study of a suspension footbridge using hybrid slotted bolted connection elements.» *Engineering Structures*, 2006.
- [4]  
P. Eriksson, Thesis : Vibration response of lightweight pedestrian bridges, 2013.
- [5]  
M. Pantak, B. Jarek et K. Marecik, «Vibration damping in steel footbridges,» chez *IOP Conference Series : Materials Science and Engineering*, 2018.
- [6]  
Hammerum, Keld & Brath, Per & Poulsen and Niels, "A fatigue approach to wind turbine control," *Journal of Physics*, p. 111, 2007.
- [7]  
I. Rychlik, «On the 'narrow-band' approximation for expected fatigue damage,» *Elsiever*, 1993.
- [8]  
I. Rychlik, «A new definition of the rainflow counting method,» *International journal of fatigue*, 1987.
- [9]  
M. Mršnik, J. Slavič et M. Boltežar, «Frequency-domain methods for a vibration-fatigue-life estimation – Application to real data,» *International Journal of Fatigue*, 2013.
- [10]  
W. Zhao et M. J. Baker, «On the probability density function of rainflow stress range,» *Int J Fatigue*, 1992.
- [11]  
D. Benasciutti et R. Tovo, «Spectral methods for lifetime prediction under wideband,» *Int J Fatigue*, 2005.
- [12]  
T. Dirlik, «Application of computers in fatigue analysis,» *Ph.D. thesis - The University Of Warwick*, 1985.
- [13]  
E. T. Matsuishi M, «Fatigue of metals subject to varying stress,» *Paper*, 1968.
- [14]  
B. Laulagnet, *Cours de vibrations des systemes discrets*, Villeurbanne: INSA Lyon moodle 3GM.
- [15]  
Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi, You Only Look Once : Unified, Real-Time Object Detection, 2016.
- [16]  
Ross Girshick, Jeff Donahue, Trevor Darrell, Jitendra Malik, Rich feature hierarchies for accurate object detection and semantic segmentation, 2014.
- [17]  
Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegzdy, Scott Reed, Cheng-Yang Fu, Alexander C. Berg, SSD : Single Shot MultiBox Detector, 2016.
- [18]  
Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun, Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition, 2015.