

Commande garantie pour le contrôle et la prévention de l'endommagement des structures

Daniel Martin Xavier¹, Ludovic Chamoin¹, Laurent Fribourg²

¹ Université Paris-Saclay, CentraleSupélec, ENS Paris-Saclay, CNRS, LMPS - Laboratoire de Mécanique Paris-Saclay, 91190, Gif-sur-Yvette, France, {daniel.martin_xavier, ludovic.chamoin}@ens-paris-saclay.fr

² Université Paris-Saclay, CNRS, ENS Paris-Saclay, Laboratoire de Méthodes Formelles, 91190, Gif-sur-Yvette, France
laurent.fribourg@ens-paris-saclay.fr

Résumé — Ce travail propose l'utilisation des réseaux de neurones pour simuler efficacement la stratégie *Model Predictive Control* (MPC). On montre ici qu'en entraînant un réseau de neurones hors ligne, on obtient un gain de performance qui permet de contrôler en temps réel l'évolution de l'endommagement dans des structures composites. On compare la performance du contrôleur proposé par rapport au MPC classique sur un exemple académique puis sur un cas test réel mettant en oeuvre un chargement piloté par un hexapode pour limiter le niveau d'endommagement d'une structure.

Mots clés — Contrôle de Santé Intégré, Réseaux de Neurones, Endommagement, Model Predictive Control, Dynamic Data Driven Application Systems.

1 Introduction

Les matériaux composites présentent des propriétés mécaniques avantageuses, et sont largement utilisés dans l'industrie automobile et aéronautique pour la fabrication de pièces complexes. Par conséquent, les ingénieurs s'intéressent de plus en plus à la durabilité et la sécurité des structures composites. Ceci nécessite l'évaluation et le suivi des dommages subis par ces structures tout au long de leur vie (SHM). Dans ce contexte, la maîtrise de l'endommagement est fondamentale pour prolonger la durée de vie des structures, ainsi que pour mettre en oeuvre une maintenance prédictive.

Cette thématique fait actuellement l'objet de recherche du projet ERC DREAM-ON (2021 - 2026), au sein duquel s'inscrit le présent travail. Le projet vise à associer la structure mécanique à un jumeau numérique qui est mis à jour et enrichi à la volée, permettant de contrôler en temps réel l'évolution de l'endommagement [1]. L'objectif est de passer des "matériaux intelligents" aux "structures intelligentes", capables de surveiller de manière autonome leur état de santé, et de fonctionner en toute sécurité en mode dégradé.

Le développement d'un tel projet nécessite la mise en place d'un Contrôle Santé Intégré (CSI) permettant la détection et la caractérisation en temps réel des dommages sur une structure. Cela constitue le cœur du concept *Dynamic Data Driven Application Systems* (DDDAS), qui vise à renforcer le couplage entre les données expérimentales et le jumeau numérique [2]. Cela permet d'effectuer des inférences à la volée à partir des observations *in situ*, de mettre à jour le jumeau numérique en temps réel, et de faire le diagnostic et le pronostic des dommages en temps réel.

En outre, le paradigme DDDAS permet de développer un contrôleur robuste qui adapte le fonctionnement de la structure pour éviter de sortir d'une zone de sécurité. Par exemple, le contrôleur peut réduire la charge ou appliquer des forces d'amortissement en réponse à des conditions de chargement ou à une diminution des capacités de la structure [1]. En conséquence, il devient possible de préserver son intégrité structurelle, d'assurer un fonctionnement sûr même en mode dégradé, et de planifier une maintenance optimisée.

Le présent travail s'intéresse à l'aspect contrôle au sein du projet ERC. Il vise à concevoir une stratégie de contrôle robuste pour les structures évolutives, non linéaires et endommageables soumises à des contraintes liées à leur intégrité structurelle. Dans ce contexte, la stratégie *Model Predictive Control* (MPC) semble la plus appropriée, bien que son importante exigence en temps de calcul complique sa mise en oeuvre en temps réel. Afin de pallier ce problème, on propose de simuler un MPC par un réseau

de neurones capable de générer rapidement une loi de commande.

Dans la suite de ce document, la Section 2 offre une vue d'ensemble du projet DREAM-ON ainsi que de la contribution de ce travail au sein du projet global. La Section 3 présente l'erreur en relation de comportement (mCRE), tandis que la Section 4 introduit la stratégie MPC classique et les approches *data-driven*, illustrées par des résultats préliminaires basés sur un exemple académique. Enfin, la Section 5 rassemble les conclusions de cette étude et propose les perspectives de travaux futurs.

2 Présentation du projet DREAM-ON

Le projet DREAM-ON a pour objectif d'établir un cadre dans lequel la simulation et les mesures échangent des informations en temps réel, s'inscrivant ainsi dans le paradigme DDDAS [1]. L'idée principale réside dans la mise en place d'une boucle de contrôle entre le système réel et son jumeau numérique, dans le but d'améliorer la fiabilité des jumeaux numériques et de renforcer la robustesse des systèmes [2].

Dans le contexte du Contrôle Santé Intégré (CSI), le paradigme DDDAS consiste à prédire l'évolution de l'endommagement à l'aide de jumeaux numériques, ce qui permet au contrôleur de gérer l'impact des dommages structurels. Parallèlement, des mesures *in situ* sont assimilées à la volée pour évaluer dynamiquement l'état du système et mettre à jour le jumeau numérique. Ces informations sont utilisées pour surveiller les structures composites en caractérisant leurs défauts, en prévoyant leur durabilité, et en anticipant les mesures nécessaires pour éviter les défaillances.

Le paradigme DDDAS renforce la fiabilité des jumeaux numériques et accroît la robustesse du système en intégrant simultanément les connaissances *a priori* et les données expérimentales [2]. Bien que ce concept remonte à plus de dix ans [3], son utilisation pour le CSI sur des structures endommageables réelles demeure une problématique ouverte, en raison des défis numériques liés à sa mise en œuvre.




FIGURE 1 – Diagramme de la boucle de contrôle proposée dans le cadre du projet DREAM-ON.

Le projet DREAM-ON est schématisé sur la Figure 1, et se divise en trois parties : la première a pour objectif de concevoir une stratégie d'assimilation des données bruitées relatives à l'état de santé de la structure. Dans ce contexte, des capteurs par fibres optiques basés sur la rétrodiffusion élastique de Rayleigh sont employés pour récupérer des informations sur les déformations locales au sein du matériau [4]. Cette technologie permet une détection précise des déformations, qui sont ensuite converties en une cartographie des dommages affectant l'ensemble de la structure.

En parallèle des techniques de détection, les outils de modélisation et de simulation des dommages représentent un élément clé de la deuxième partie du projet. Le choix de jumeau numérique pour simuler le comportement des matériaux composites dépend de plusieurs variables telles que leur composition, leur architecture, leur géométrie et leur historique de chargement. L'objectif est donc de développer un modèle d'endommagement à plusieurs échelles, en recherchant un équilibre entre précision et complexité, en fonction des données expérimentales disponibles.

La dernière partie du projet consiste à mettre en place une stratégie de contrôle qui demeure robuste et stable lorsqu'elle est appliquée aux systèmes dynamiques évolutifs et non linéaires. Le contrôleur doit être en mesure de générer une loi de commande garantie en se basant sur les prédictions de l'endommagement fournies par le jumeau numérique, et en tenant compte des diverses sources d'incertitude (sur les mesures et le modèle). L'objectif est d'empêcher que la structure opère en dehors d'une zone de sécurité garantissant son intégrité structurelle.

Ici, des contraintes physiques sont intégrées au contrôleur pour confiner la solution optimale à une région de sécurité, ce qui justifie l'utilisation d'un MPC. Cette stratégie repose sur la résolution d'un problème d'optimisation sous contraintes sur un horizon fuyant [5] pour assurer que la structure ne franchisse jamais les contraintes imposées. Le MPC est également capable de contrôler des systèmes non linéaires tout en prenant en compte les incertitudes liées à la modélisation (comportement du matériau, conditions limites), aux capteurs et aux données.

Parmi les trois domaines de recherche du projet DREAM-ON, ce travail se concentre sur la conception d'un contrôleur garanti pour des applications en temps réel, identifié par le cadre rouge sur la Figure 1. Ce travail propose de remplacer l'optimisation d'un MPC classique par un réseau de neurones, dans le but de réduire le temps de calcul et de le rendre plus adapté aux applications de CSI. À cette fin, le réseau est préalablement entraîné hors ligne en utilisant des données extraites d'une simulation MPC, puis il est employé pour contrôler le système en temps réel [6].

Une difficulté inhérente à ce projet réside dans le fait que, à mesure que le système subit des dommages, la zone de sécurité correspondante diminue progressivement. Par conséquent, la conception d'un contrôleur capable de prendre en compte des contraintes dynamiques est essentielle. L'objectif de ce travail est de garantir que la loi de commande synthétisée par le réseau de neurones répond aux exigences de sécurité compte tenu de la dégradation de la structure.

3 Erreur en relation de comportement modifiée (mCRE)

Avant la conception du contrôleur, un aspect fondamental du paradigme DDDAS est le recalage de paramètres du jumeau numérique en utilisant d'observations bruitées et indirectes. Certains de ces paramètres décrivent l'état du système et l'évolution de l'endommagement, et ils sont déterminés en résolvant un problème inverse. Dans le cadre du projet DREAM-ON, l'erreur en relation de comportement modifiée (mCRE) est utilisée pour recalibrer le jumeau numérique [7], corriger le biais de modélisation [8], et obtenir une estimation complète de l'état du système.

L'approche mCRE repose sur la fiabilité de l'information, c'est-à-dire le niveau de connaissance *a priori* du modèle et des mesures. L'information est donc divisée en deux parties : une partie fiable (e.g., les équations d'équilibre), qui est imposée à travers un espace d'admissibilité, et une partie non fiable (e.g., les relations de comportement), qui est relâchée et satisfaite au mieux. Les paramètres et les champs mécaniques sont ensuite déterminés en recherchant le meilleur compromis entre les informations issues des données mesurées et les connaissances physiques.

Par exemple, si le potentiel Ψ décrit une loi hyper-élastique reliant la déformation ε à la contrainte σ , le problème inverse peut être formulé en supposant que les mesures Y_{obs} et la relation de comportement $\mathcal{M}(\hat{\varepsilon}; \mathbf{p})$ sont non fiables. La procédure mCRE consiste alors à appliquer une minimisation sous contrainte de la forme :

$$\mathbf{p}_{sol} = \arg \min_{\mathbf{p} \in \mathcal{P}} \left[\min_{(\hat{\varepsilon}, \hat{\sigma}) \in (\mathcal{A}_d)} \eta_{mCRE}^2(\hat{\varepsilon}(\hat{\mathbf{u}}), \hat{\sigma}) \right] \quad (1)$$

$$\eta_{mCRE}^2(\hat{\varepsilon}, \hat{\sigma}; \mathbf{p}) = \int_{\Omega} (\Psi(\hat{\varepsilon}) + \Psi^*(\hat{\sigma}) - \hat{\sigma} : \hat{\varepsilon}) + \alpha \|\Pi \circ \mathcal{M}(\hat{\varepsilon}; \mathbf{p}) - Y_{obs}\|^2 \quad (2)$$

où α désigne un coefficient de pondération, $\Psi^*(\hat{\sigma})$ le potentiel dual de $\Psi(\hat{\varepsilon})$ au sens de la transformation de Legendre-Fenchel, Ω le domaine physique occupé par la structure mécanique, et Π le projecteur des résultats du modèle aux endroits où les observations sont mesurées. Les paramètres \mathbf{p} , ainsi que le couple admissible $(\hat{\varepsilon}, \hat{\sigma}) \in \mathcal{A}_d$, sont déterminés à travers une minimisation itérative de la fonctionnelle mCRE.

Cette fonctionnelle est composée d'un premier terme d'erreur en relation de comportement (erreur de modélisation) et d'un deuxième terme d'écart aux observations (distance de Mahalanobis). Elle est

capable de prendre en considération toutes les sources d'erreurs et d'incertitudes, ce qui la rend naturellement adaptée à la résolution des problèmes inverses. Couplée aux techniques d'assimilations de données comme le filtre de Kalman, il est possible de suivre l'état d'une structure en temps réel dans le cadre des applications CSI.

Dans ce contexte, Diaz et al. [7] ont proposé l'algorithme *Modified Dual Kalman Filter* (MDKF) comme une méthode robuste pour l'identification de la rigidité d'une structure à partir des mesures bruitées. Dans le domaine du contrôle, la mCRE permet aussi d'obtenir les champs admissibles optimaux récupérés à partir des paramètres du modèle et des mesures, ce qui donne accès à l'état complet du système et à un modèle recalé [9]. Ainsi, l'objectif du projet DREAM-ON est de réussir à coupler la mCRE, le filtre de Kalman et le MPC afin de générer une commande basée sur un jumeau numérique recalé où tous les états du système sont accessibles.

4 Model Predictive Control

La stratégie *Model Predictive Control* (MPC), l'une des stratégies de contrôle les plus répandues dans l'industrie, repose sur une approche à horizon fuyant. Elle utilise un modèle mathématique pour prédire les états futurs du système et calculer la commande à appliquer à travers la résolution d'un problème d'optimisation quadratique [10]. À l'origine, cette méthode a été employée dans les usines chimiques et les raffineries de pétrole, afin de prendre en compte des contraintes physiques inhérentes à ces secteurs industriels [11]. Ces systèmes se caractérisaient par leur dynamique non linéaire et de la multiplicité des entrées et sorties, ce qui rend le contrôle plus complexe [12].

Avec l'émergence des réseaux de neurones, plusieurs travaux ont proposé de remplacer le modèle mathématique d'un MPC classique par un modèle basé sur les données. Par exemple, Dräger et al. [13] ont utilisé les prédictions d'un réseau de neurones pour contrôler le pH dans un réacteur de neutralisation. D'autres recherches se sont intéressées à la détermination de l'ensemble terminal à partir des données, afin d'améliorer la stabilité du contrôleur. Berberich et al. [14] ont proposé une stratégie visant à obtenir l'ensemble terminal et le coût terminal d'un problème d'optimisation sous contraintes à partir de données d'entrée-sortie mesurées.

Le présent travail vise à remplacer l'optimisation d'un contrôleur MPC classique par un réseau de neurones afin d'accroître la vitesse de calcul et le rendre plus adapté aux applications en temps réel. Le réseau de neurones est entraîné en utilisant les données engendrées lors d'une simulation MPC hors ligne, ce qui permet de contrôler en temps réel l'évolution de l'endommagement dans les structures composites. Cette approche se distingue de la littérature existante en proposant le contrôle efficace et rapide des systèmes fortement non linéaires.

4.1 Exemple académique - Oscillateur de Van der Pol

Afin de valider la stratégie *data-driven* MPC proposée, un exemple académique est mis en place pour évaluer les performances du contrôleur. Dans la suite, le MPC classique a été implémenté en utilisant la MPC Toolbox sur Python [15], qui résout les équations algébriques différentielles du modèle non linéaire via le solveur CVODE Sundials, ainsi que le problème d'optimisation à l'aide de la méthodes des points intérieurs [16].

L'oscillateur de Van der Pol est un système dynamique classique utilisé dans la validation des stratégies de contrôle optimal [17]. Le système est caractérisé par deux états $\mathbf{x} = [x_1, x_2]$, une commande u et un coefficient d'amortissement $\mu = 1$, étant décrit par :

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = \mu(1 - x_1^2)x_2 - x_1 + u \end{cases} \quad (3)$$

Dans un premier temps, le MPC classique est employé pour conduire le système vers une position de référence x_1^{ref} . Les données engendrées lors de cette simulation sont ensuite collectées pour entraîner un réseau de neurones hors ligne qui remplacera l'optimisation. La simulation MPC a été configurée avec un pas de temps $T_s = 0,5s$, un horizon de prédiction $N = 5$ et une condition initiale $\mathbf{x}_0 = [1, 0]$. La commande appliquée à l'oscillateur a été contrainte à l'intervalle $u \in [-1, 1]$, et la fonction coût associée au problème d'optimisation a été formulée comme suit :

$$J(\mathbf{x}, \mathbf{u}) = \sum_{i=0}^{N-1} \|x_1^{ref}(k+i) - x_1(k+i)\|_2 + \alpha \|\Delta u(k+i)\|_2 \quad (4)$$

$$\text{s. t. } u_{lb} \leq u(k+i) \leq u_{ub}, \quad \forall i \in [0, \dots, N-1] \quad (5)$$

où u_{lb} et u_{ub} désignent respectivement les bornes inférieure et supérieure de la commande, $\Delta u(k)$ représente la variation de la commande sur un pas de temps, et $\alpha = 0.1$ est un coefficient de pondération. D'ailleurs, le pas de temps actuel est noté k , et l'erreur en position par rapport à la référence est définie comme $\varepsilon(k) = x_1 - x_1^{ref}$.

La simulation MPC se déroule hors ligne en définissant plusieurs références engendrées aléatoirement entre $[-1, 1]$, chaque référence étant appliquée pendant $10s$. Le modèle non linéaire du système a été mis en œuvre à l'aide de CasADi [18], avec le même pas de temps du contrôleur ($T_s = 0,5s$). La simulation MPC s'étend sur une durée de $1800s$, générant ainsi $n = 3600$ données réparties en 3 ensembles : $n_{train} = 2160$ pour l'entraînement, $n_{val} = 720$ pour la validation et $n_{test} = 720$ pour le test.

Une fois les données collectées, un réseau de neurones à un coup d'avance, dont l'architecture est montrée dans la Figure 2, est conçu avec une couche cachée. Ce réseau comporte trois entrées dans la première couche, dix neurones dans la couche cachée, et une sortie dans la dernière couche. Son implémentation a été réalisée à l'aide de PyTorch [19] avec la fonction d'activation ReLU appliquée à la couche cachée et la fonction Hardtanh utilisée dans la couche de sortie pour contraindre la commande à l'intervalle $[-1, 1]$.




FIGURE 2 – Architecture du réseau de neurones employée pour simuler une optimisation sous contraintes dans un contrôleur MPC classique.

Le réseau de neurones a été entraîné en $76,29s$ à l'aide de l'algorithme d'optimisation AdamW [20] sur une période de 10^3 époques avec un taux d'apprentissage de $\eta = 10^{-2}$. Pour évaluer sa capacité de généralisation, les performances du réseau entraîné ont été vérifiées sur l'ensemble de test, comprenant des données qui n'avaient jamais été utilisées lors de l'apprentissage. La Figure 3 présente une comparaison entre la commande MPC et les prédictions du réseau sur l'ensemble de test, mettant en évidence l'efficacité du réseau de neurones pour simuler un problème d'optimisation.

Afin d'obtenir une mesure quantitative de la performance du réseau, l'erreur quadratique moyenne a été utilisée comme métrique d'évaluation, définie comme suit :

$$L_{test} = \frac{1}{n_{test}} \sum_{i=1}^{n_{test}} (u_i^{MPC} - u_i^{NN})^2 \quad (6)$$

où u_i^{MPC} représente la commande MPC et u_i^{NN} correspond à la commande prédite par le réseau de neurones. Lorsqu'évalué sur l'ensemble de test, le réseau de neurones est capable de reproduire le




FIGURE 3 – Comparaison entre la commande MPC (u^{MPC}) et les prédictions du réseau de neurones (u^{NN}) sur l'ensemble de test.

comportement d'un MPC classique avec une erreur de $L_{\text{test}} = 0.0015$, ce qui suggère une généralisation satisfaisante sur des données en dehors de l'ensemble d'apprentissage. Après avoir vérifié la capacité de généralisation du réseau de neurones, le contrôleur *data-driven* MPC est utilisé en ligne pour piloter l'oscillateur de Van der Pol, afin d'évaluer sa performance en boucle fermée.

La Figure 4 illustre la performance du contrôleur *data-driven* MPC par rapport au MPC classique dans une simulation en boucle fermée. Le système a été initialisé à l'état $x_0 = [-0.3, 0]$, et les consignes à suivre correspondent aux références en position issues de l'ensemble de test. En comparaison au MPC classique, la stratégie proposée entraîne un dépassement plus important pendant la convergence, ce qui est corroboré par une légère augmentation de l'erreur quadratique moyenne.




FIGURE 4 – Comparaison entre les contrôleurs MPC classique (orange) et le *data-driven* MPC (bleu) en boucle fermée.

Le Tableau 1 présente une comparaison quantitative entre les deux stratégies de contrôle, confirmant ainsi une dégradation des performances du *data-driven* MPC par rapport au contrôleur classique. Cependant, il est important de noter que le MPC classique nécessite 20 fois plus de temps que sa version *data-driven* pour calculer la prochaine commande, une fois qu'il doit résoudre une optimisation sous contraintes à chaque pas de temps. À mesure que l'horizon de prédiction augmente ($N > 5$), cet écart devient plus prononcé, ce qui rend le *data-driven* MPC plus adapté aux applications en temps réel.

Comme précédemment mentionné, l'objectif de la stratégie *data-driven* MPC est d'améliorer le temps de calcul de la commande, ce qui a été réalisé au détriment des performances du contrôleur. Les résultats présentés dans ce travail démontrent que le réseau de neurones parvient à reproduire de manière satisfaisante le comportement d'un MPC classique tout en généralisant efficacement sur les données en

TABLE 1 – Évaluation des performances des contrôleurs dans une simulation en boucle fermée.

Strategy	MSE	Computation Time (ms)
MPC	0.252	2.466
NN	0.314	0.115

dehors de l'ensemble d'apprentissage. De plus, la stratégie *data-driven* MPC s'est avérée efficace dans le suivi d'une consigne tout en réduisant le coût de calcul de la commande, ce qui la rend plus appropriée pour des applications en temps réel.

4.2 Preuve de concept - Contrôle Santé Intégré

Les résultats obtenus avec l'oscillateur de Van der Pol mettent en évidence l'efficacité de la stratégie *data-driven* MPC sur un exemple simple, ce qui confirme sa pertinence pour le contrôle de systèmes non linéaires. Les perspectives de ce travail impliquent la mise en œuvre d'une preuve de concept sur une plateforme hexapode, dans le but de valider la méthodologie DDDAS pour les applications CSI. Ceci consiste à soumettre des éprouvettes en carbone-époxy à un chargement multi-axial afin de maîtriser l'endommagement induit dans la pièce en utilisant la boucle de contrôle illustrée dans la Figure 5.




FIGURE 5 – Schéma de la preuve de concept utilisée pour valider la méthodologie DDDAS.

Les données sur l'endommagement sont acquises à 5 Hz par un réflectomètre optique à rétro-diffusion (OBR-4600) et associé à des capteurs à fibre optique. Ce dispositif permet une détection à haute résolution et une interrogation des données en temps réel en utilisant la technique MDKF. De plus, l'hexapode H-850 [21] est employé pour engendrer un chargement multi-axial dans la pièce à partir des commandes de translation (u_x, u_y, u_z) et rotation (u_ϕ, u_θ, u_ψ). L'objectif est d'atteindre une position souhaitée tout en préservant l'intégrité de la structure pour différentes conditions d'endommagement initiales. Les résultats préliminaires seront présentés lors de la conférence.

5 Conclusions et perspectives

Ce travail s'est consacré à la conception d'un contrôleur garanti destiné aux structures composites endommageables, en vue de son utilisation dans des applications CSI. La stratégie de contrôle proposée consiste à entraîner un réseau de neurones à partir des données engendrées par un MPC, puis à le déployer en ligne. Les simulations ont montré que le MPC classique apporte une légère amélioration de la précision par rapport à la version *data-driven*. Cependant, cette dégradation de la performance est compensée par une réduction significative du temps de calcul nécessaire pour générer la commande. Les perspectives de ce travail se concentrent sur l'étude de la convergence de l'erreur d'entraînement du réseau de neurones en utilisant le concept de *Neural Tangent Kernel* et la détermination d'une borne supérieure pour l'erreur de généralisation.

Remerciement

Ce projet a reçu un financement du European Research Council (ERC) dans le cadre du programme de recherche et d'innovation Horizon 2020, au titre de la convention No. 101002857.

Références

- [1] Ludovic Chamoin. Merging advanced sensing techniques and simulation tools for future structural health monitoring technologies. *The Project Repository Journal*, 10 :124–127, 09 2021.
- [2] National Science Foundation (U.S.). *Simulation-based Engineering Science : Revolutionizing Engineering Science Through Simulation*. National Science Foundation, 2006.
- [3] Frederica Darema. Dynamic data driven applications systems : A new paradigm for application simulations and measurements. In Marian Bubak, Geert Dick van Albada, Peter M. A. Sloom, and Jack Dongarra, editors, *Computational Science - ICCS 2004*, pages 662–669, Berlin, Heidelberg, 2004. Springer Berlin Heidelberg.
- [4] Mark Froggatt and Jason Moore. High-spatial-resolution distributed strain measurement in optical fiber with rayleigh scatter. *Appl. Opt.*, 37(10) :1735–1740, Apr 1998.
- [5] Francesco Borrelli, Alberto Bemporad, and Manfred Morari. *Predictive Control for Linear and Hybrid Systems*. Cambridge University Press, 2017.
- [6] Steven W. Chen, Tianyu Wang, Nikolay Atanasov, Vijay Kumar, and Manfred Morari. Large scale model predictive control with neural networks and primal active sets. *Autom.*, 135 :109947, 2022.
- [7] Matthieu Diaz, Pierre-Étienne Charbonnel, and Ludovic Chamoin. Fully automated model updating framework for damage detection based on the modified Constitutive Relation Error. *Computational Mechanics*, September 2023.
- [8] Antoine Benady, Emmanuel Baranger, and Ludovic Chamoin. A modified Constitutive Relation Error (mCRE) framework to learn nonlinear constitutive models from strain measurements with thermodynamics-consistent Neural Networks. In *XI Conference on Adaptive Modeling and Simulation*, Gothenburg, France, June 2023.
- [9] Fabien Formosa. *Contribution à l'amélioration de la modélisation de structures légères en vue de leur contrôle actif*. Phd thesis, ENS Cachan, 61 Avenue Président Wilson, France, December 2002.
- [10] Max Schwenzer, Muzaffer Ay, Thomas Bergs, and Dirk Abel. Review on model predictive control : an engineering perspective. *The International Journal of Advanced Manufacturing Technology*, 117 :1–23, 11 2021.
- [11] S.Joe Qin and Thomas A. Badgwell. A survey of industrial model predictive control technology. *Control Engineering Practice*, 11(7) :733–764, 2003.
- [12] David Q. Mayne. Model predictive control : Recent developments and future promise. *Automatica*, 50(12) :2967–2986, 2014.
- [13] A. Draeger, S. Engell, and H. Ranke. Model predictive control using neural networks. *IEEE Control Systems Magazine*, 15(5) :61–66, 1995.
- [14] Julian Berberich, Johannes Köhler, Matthias A. Müller, and Frank Allgöwer. On the design of terminal ingredients for data-driven mpc. *IFAC-PapersOnLine*, 54(6) :257–263, 2021. 7th IFAC Conference on Nonlinear Model Predictive Control NMPC 2021.
- [15] S. Lucia, A. Tatulea-Codrean, C. Schoppmeyer, and S. Engell. Rapid development of modular and sustainable nonlinear model predictive control solutions, 2017.
- [16] Yu. Nesterov. Interior-point methods : An old and new approach to nonlinear programming. *Math. Program.*, 79(1–3) :285–297, oct 1997.
- [17] Eric Aislan Antonelo, Eduardo Camponogara, Laio Oriel Seman, Eduardo Rehbein de Souza, Jean P. Jordanou, and Jomi F. Hubner. Physics-informed neural nets for control of dynamical systems, 2022.
- [18] Joel A E Andersson, Joris Gillis, Greg Horn, James B Rawlings, and Moritz Diehl. CasADi – A software framework for nonlinear optimization and optimal control. *Mathematical Programming Computation*, 11(1) :1–36, 2019.
- [19] Adam Paszke, Sam Gross, Francisco Massa, Adam Lerer, James Bradbury, Gregory Chanan, Trevor Killeen, and Zeming Lin et al. Pytorch : An imperative style, high-performance deep learning library. In *Advances in Neural Information Processing Systems 32*, pages 8024–8035. Curran Associates, Inc., 2019.
- [20] Ilya Loshchilov and Frank Hutter. Decoupled weight decay regularization. In *International Conference on Learning Representations*, 2019.
- [21] PI. *6-Axis Hexapod*. PI.