



HAL
open science

Optimisation du pilotage industriel d'une piscine publique grâce à la modélisation dirigée par les données : proposition d'un jeu de données applicatif

François Gauthier-Clerc, Hoel Le Capitaine, Fabien Claveau, Philippe Chevrel

► To cite this version:

François Gauthier-Clerc, Hoel Le Capitaine, Fabien Claveau, Philippe Chevrel. Optimisation du pilotage industriel d'une piscine publique grâce à la modélisation dirigée par les données : proposition d'un jeu de données applicatif. 9ème Conférence Nationale sur les Applications Pratiques de l'Intelligence Artificielle APIA@PFIA2023, AFIA-Association Française pour l'Intelligence Artificielle; ICube-laboratoire des sciences de l'ingénieur, de l'informatique et de l'imagerie, Jul 2023, Strasbourg, France. pp.81-87. hal-04159407

HAL Id: hal-04159407

<https://hal.science/hal-04159407v1>

Submitted on 11 Jul 2023

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

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



Distributed under a Creative Commons Attribution 4.0 International License

Optimisation du pilotage industriel d'une piscine publique grâce à la modélisation dirigée par les données : proposition d'un jeu de données applicatif.

François Gauthier-Clerc^{1,2,3}, Hoel Le Capitaine^{2,4}, Fabien Claveau^{2,3} Philippe Chevreil^{2,3}

¹Purecontrol, 68 Av. Sergent Maginot, 35000 Rennes, FRANCE

²LS2N – Laboratory of digital sciences of Nantes, UMR CNRS 6004, BP 92208, 44322 Nantes

³IMT Atlantique, CS 20722, 44307 Nantes, FRANCE

⁴Nantes Université, Polytech Nantes, 44306 Nantes

Résumé

Cet article met en évidence l'importance de modèles dirigés par les données pour la modélisation/pilotage de systèmes dynamiques. Il recommande l'utilisation de modèles précis et capable d'extrapolation pour un pilotage générique. L'étude se base sur l'exemple d'une piscine publique et montre les difficultés d'obtenir un bon modèle dans un contexte de données réelles. Un jeu de données issu d'un système réel et des critères de performance sont proposés pour aider à améliorer les techniques d'apprentissage et d'identification en vue d'une meilleure optimisation énergétique de nombreuses installations industrielles.

Mots-clés

Modélisation de systèmes dynamiques, Optimisation énergétique, Apprentissage automatique

Abstract

This article highlights the importance of data driven models for the modeling and control of dynamic systems. It recommends the use of accurate and consistent models for data-driven control. The study is based on the example of a public swimming pool and demonstrates the difficulties of optimizing a model in a real-world data context. A dataset from a real system and calibrated performance criteria are proposed to improve the techniques of learning and identifying systems for better energy optimization of numerous industrial installations.

Keywords

Dynamic systems modeling, Energy optimization, Machine learning

1 Introduction

Les besoins en énergie et en matières premières sont en constante augmentation et doivent être gérés au mieux afin d'éviter les pénuries et l'augmentation des coûts de production. L'augmentation de la part des énergies renouvelables dans le mix énergétique rend le marché de l'énergie toujours plus volatile, ce qui impose aux installations énergivores une plus grande flexibilité.

L'amélioration continue des postes de consommation énergétique joue un rôle important dans la transition énergétique. L'adaptation de la consommation face à la production et à l'augmentation du rendement des installations sont les deux vecteurs à privilégier. Malgré des systèmes modernes de plus en plus efficaces, la mise aux normes par le remplacement n'est pas une solution viable dans tous les cas et d'autant plus dans un marché des matières premières en tension.

À partir de ces observations, la nécessité d'améliorer les installations existantes par une meilleure régulation est une option permettant de répondre au problème tout en ayant un coût de déploiement marginal.

Aujourd'hui, de nombreuses installations sont contrôlées par des régulateurs simples tels que des régulateurs PID (proportionnel, intégral, dérivé) qui ne répondent qu'à une consigne fixe. La mise en place d'une approche experte avec une notion d'optimalité est coûteuse et inaccessible pour beaucoup d'entreprises.

Les piscines publiques font partie de cette catégorie d'installations où les besoins en eau chaude ne sont pas constants (nuit vs jour). Les déperditions de chaleur ainsi que le coût monétaire moyen du chauffage peuvent être des vecteurs d'économies pour l'installation [13]. Malheureusement, les coûts de fonctionnement de ce type d'installations ne permettent pas le financement de solutions de régulation plus avancées.

On note dans la littérature des méthodes expertes permettant d'optimiser le coût de chauffage. Les méthodes les plus simples consistent à formuler une planification de consigne de température sur la semaine [16]. Dans le contexte de la piscine, cette réduction de température peut permettre une économie allant jusqu'à 7% [12]. On peut retrouver dans la littérature d'autres approches plus avancées d'ordonnement [5]. Malheureusement, ce genre d'approche est très spécifique et donc peu généralisable et s'adapte difficilement à un changement de dynamique de système (température extérieure, par exemple).

On constate une popularité croissante des approches prédictives basées sur des modèles, qui permettent, à partir des

contraintes métier et d'une fonction de coût, de synthétiser une loi de commande pour piloter efficacement les installations. Parmi ces approches, on peut citer les approches par apprentissage par renforcement (ou RL *Reinforcement Learning*) [1] ainsi que les méthodes EMPC (*Economical model predictive control*) [13]. Ces méthodes se reposent soit sur un simulateur [1, 10], soit sur des modèles physiques [23] ou encore avec des modèles dirigés par les données [21].

Dans le contexte de réduction des coûts, les approches basées sur les données doivent être privilégiées, car elles nécessitent peu de développement et de calibration spécifique. Cela est d'autant plus vrai pour les modèles purement basés sur les données, où presque aucune connaissance n'est donnée [19]. Dans ce contexte, l'utilisation d'approches telles que EMPC ou RL est limitée par la validité partielle du modèle [15]. En effet, le travail sur les données réelles implique de faibles marges de manœuvre sur la génération du jeu de données d'entraînement. Par conséquent, une application naïve de méthode de contrôle avec un modèle appris n'est pas envisageable. Nous tacherons dans cet article d'en faire l'illustration.

Les approches de *transfer learning* [4] offrent également une alternative pour les méthodes basées sur les données. Ces dernières utilisent des outils de simulation afin de pré-entraîner le modèle avant de le spécialiser sur les données réelles. Ces méthodes ont malheureusement le défaut de nécessiter un simulateur, ce qui donne le même désavantage que les pilotages dédiés nécessitant des experts, rendant l'approche onéreuse.

Pour aider au développement de nouvelles méthodes répondant à cette problématique dans un contexte de jeu de données collecté sur un système industriel réel, cette contribution met à disposition les données d'une piscine publique avec des critères de performance associés dans l'optique d'une utilisation en contrôle.

Ce document présentera le système de la piscine ainsi que les besoins de prédiction pour la régulation. Puis, un rapide état de l'art des méthodes d'identification basées sur les données sera fait avant d'en montrer les limites pour le contrôle. Pour terminer, le jeu de données proposé à la communauté sera détaillé ainsi que les premiers résultats avec deux modèles sélectionnés.

Nous utiliserons de manière équivalente les termes d'identification de systèmes (terme d'automatisme) et de prédiction de séries temporelles ou *time series forecasting* (terme d'apprentissage automatique).

2 Piscine publique et son contrôle

2.1 La régulation des bassins

Les piscines publiques sont des systèmes où la température et la qualité de l'eau des bassins sont deux grandeurs à réguler. Pour la partie chauffage, on trouve généralement un système de chauffage central et une distribution de chaleur par la recirculation d'une boucle d'eau chaude. L'énergie est ensuite transférée à l'aide d'un échangeur thermique eau-eau et régulée à l'aide d'une vanne 3 voies (V3V) per-




FIGURE 1 – Schéma entrée sortie du bassin

mettant de faire varier la quantité d'eau passant dans la partie chaude de l'échangeur.

Chaque bassin dispose de sa boucle de recirculation de l'eau permettant le chauffage et le nettoyage de l'eau. Un bassin tampon est également présent pour adapter la quantité d'eau nécessaire suivant le volume occupé par les utilisateurs. En parallèle de ce mécanisme de recirculation, une vanne de remplissage et d'évacuation est utilisée pour le renouvellement de l'eau.

La régulation de la température de l'eau s'effectue donc par la variation du pourcentage d'ouverture de la V3V avec l'échangeur thermique. Les capacités de chauffe à l'aide de cette vanne vont, en plus de son ouverture, dépendre de la puissance fournie par la chaudière et la consommation de chaleur en parallèle du bassin visé.

En parallèle de cette dynamique de chauffe, on observe de multiples déperditions de chaleur de l'eau du bassin. Ces pertes dépendent de l'environnement du bassin ainsi que d'actions internes telles que le renouvellement de l'eau. On parle ainsi des pertes de convection, radiation, évaporation et conduction, représentées par \dot{Q}_{conv} , \dot{Q}_{rad} , \dot{Q}_{evap} et \dot{Q}_{cond} , respectivement (plus de détails ici [3]). L'ajout d'eau froide ainsi que l'ajout de chaleur par l'échangeur sont représentés par \dot{Q}_{refill} et \dot{Q}_{HE} , respectivement. La figure 1 schématise le fonctionnement et les dynamiques, ainsi que toutes les variables d'entrée, de ce système.

2.2 Cas d'étude et besoin de prédiction

Le cas d'étude visé ici est une piscine publique située en Bretagne. Cette piscine est composée de deux bassins (sportif et récréatif) ainsi que d'un spa et d'une pataugeoire. Le bassin de loisir a un volume de 212 m^3 et le bassin de natation a un volume de 672 m^3 . La piscine est alimentée en chaleur par deux chaudières, l'une au bois et l'autre au gaz. La première est la principale et celle privilégiée, tandis que la chaudière gaz est en secours.

La piscine est ouverte de 8h à 17h30 tous les jours avec une fréquentation entre 250 et 600 personnes par jour. La piscine est équipée de capteurs de retour de température pour l'air et l'eau des bassins avec une précision au centième de degré. La température cible pour les bassins de natation et de loisir est respectivement de 27 et 30 degrés. On observe également la présence de séances de bébés nageurs nécessitant une température de 32 degrés pour le bassin de loisirs.

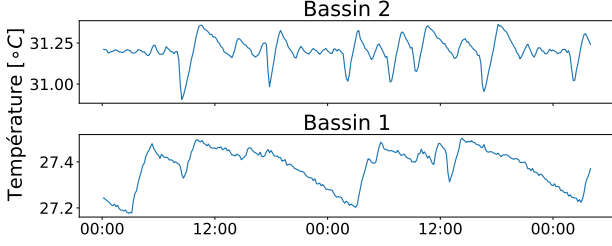


FIGURE 2 – Exemple de températures des deux bassins.

Afin de proposer une méthode efficace pour optimiser la consommation énergétique, nous proposons de se focaliser uniquement sur la régulation de la V3V des plus grands bassins (ces derniers étant les plus grands postes de consommation de l’installation). Pour le pilotage de ce sous-système, il est important de modéliser les températures des bassins qui sont les grandeurs contraintes par les besoins des utilisateurs.

Dans le cas des températures des bassins, nous avons un système relativement lent demandant des périodes de chauffe importantes suivant les demandes des utilisateurs. Cela nous impose donc un modèle précis à moyen terme (de l’ordre de 8 heures). Ce critère est imposé pour la suite du document. Le contrôle et le modèle seront formulés sur une discrétisation à 10 min en accord avec des *a priori* experts.

3 Modélisation dirigée par les données : utilisation et limitations

La modélisation dirigée par les données consiste à n’utiliser que les données comme vecteur pour la formulation d’un modèle. À l’inverse des approches basées sur la physique, ici les modèles ne se contraignent pas à la manipulation de grandeurs physiques, mais formalisent directement, ou indirectement, par des variables latentes, le système. On retrouve dans l’état de l’art une grande diversité de formulations de modèle, du modèle linéaire très simple [10] aux modèles non linéaires à approximateur universel [19]. Bien que ces méthodes semblent séduisantes, elles admettent des limites qui, dans notre contexte, sont préjudiciables à leur emploi.

3.1 État de l’art

L’identification de système est une discipline très étudiée par la communauté d’automatique [9, 19] qui a formulé l’approche sous la forme de modèles linéaires et non linéaires. On peut rapprocher cette discipline aux *time series forecasting* avec un accent sur des signaux exogènes d’entrées. Parmi les méthodes paramétriques, les modèles d’entrée sortie linéaires (ARX, ARMAX) ainsi que les modèles d’espace d’état sont les plus populaires [9]. Des extensions à ces modèles linéaires telles que les approches multi-modèles permettent d’étendre leur expressivité dans un contexte de système non linéaire.

Ces modèles ont été utilisés avec succès dans des contextes énergétiques tels que les HVAC (*heating, ventilation and air-conditioning*), que ce soit pour de la prédiction pure ou

pour du contrôle [11].

Avec l’avènement des algorithmes d’apprentissage profond, les modèles non linéaires approximateurs universels tels que les réseaux de neurones ont reçu beaucoup d’attention. On retrouve différentes formulations pour la prédiction de données temporelles, comme les modèles NLARX (*Non Linear AutoRegressive with Extra data*) [14], les réseaux récurrents [20], etc.

Ces méthodes, dans le cadre de la piscine, ont été appliquées comme méta-modèles pour la prédiction de la consommation [8]. On les retrouve également pour la modélisation de systèmes HVAC pour la prédiction de la température [20].

Ces modèles ont également été utilisés dans un contexte de pilotage basé sur les données, utilisant de l’apprentissage par renforcement [24]. Cependant, ces travaux se sont limités à l’utilisation de simulateurs permettant une bonne distribution des données d’apprentissage.

Une des formulations d’apprentissage les plus populaires, le PEM (*Prediction error minimization* [9]), consiste à minimiser le signal d’erreur entre le modèle et les données du système. Elle est très utilisée en non linéaire, car sa résolution peut être faite par descente de gradient, comme une tâche de régression classique.

Pour la suite de notre document, nous utiliserons deux modèles d’illustration, le premier linéaire utilisant la forme d’espace d’état (LSS) et la méthode des sous espaces [9].

$$\begin{aligned} x[t] &= Ax[t-1] + Bu[t-1] \\ y[t] &= Cx[t] \end{aligned} \quad (1)$$

Avec $x[t]$ représentant l’espace latent et $y[t]$ le signal à modéliser. La variable $u[t]$ représente tous les signaux exogènes sélectionnés pour la modélisation. Le second modèle choisi sera un réseau de neurones perceptron multicouche utilisant la formulation NLARX [17].

$$\begin{aligned} y[t+1] &= f_{\theta}(y[t], y[t-1], \dots, y[t-n_a], \\ &u[t], u[t-1], \dots, u[t-n_b]) \end{aligned} \quad (2)$$

Avec n_a et n_b , le nombre de délais en entrée de modèle respectivement pour y et u .

Dans notre contexte où la prédiction sur un horizon est importante, l’utilisation d’autres critères d’apprentissage que le PEM à un pas, tels que des critères de prédiction à k pas, est plus appropriée. De récentes approches de minimisation de l’erreur sur un horizon ont été proposées [7, 18] s’adaptant mieux au pilotage prédictif. Cet apprentissage peut être rattaché aux méthodes d’apprentissage des réseaux récurrents avec la méthodologie *Back Propagation Through Time* pour estimer le gradient d’une prédiction récurrente [20]. On représente le critère d’optimisation de la façon suivante :

$$V(\theta) = \mathbb{E}_{y, u \sim \mathcal{D}} \left[\sum_{k=1}^H e[t|t-k]^2 \right] \quad (3)$$

$$\text{avec } e[t|t-k] = \hat{y}[t|t-k] - y[t]$$

$\hat{y}[t|t-k]$ la prédiction récurrente du modèle sachant $y[t-k]$

et u de l'intervalle $t - k$ à t , H la profondeur de la prédiction et D le jeu de données d'entraînement. Nous utiliserons ce critère d'apprentissage pour le modèle non linéaire des sections suivantes.

3.2 Les limites de l'approche dirigée par les données

Après avoir motivé le besoin d'une approche dirigée par les données pour la modélisation, il est nécessaire d'illustrer ses limites dans un contexte de déploiement de pilotage. Pour être réaliste, l'apprentissage doit être réalisé en ligne avec un jeu de données relativement restreint et avec la potentielle impossibilité de réaliser des expériences pour l'identification (car l'installation est en exploitation).

Afin d'illustrer les limites, nous proposons de réaliser une tâche de planification de chauffage. Cette planification consiste à trouver la meilleure stratégie de pilotage en utilisant un modèle boîte noire basé sur les données. Elle doit respecter des températures minimales tout en réduisant au maximum l'ouverture moyenne de la V3V. Cette planification a pour but d'illustrer la pertinence de ce genre de modèle pour le pilotage. Le processus consiste donc à sélectionner des données d'apprentissage pour obtenir un modèle qui sera utilisé ensuite comme support pour la planification sur une autre période. Cette deuxième période est sélectionnée afin de la comparer les données réelles avec la planification obtenue. En procédant ainsi, nous pouvons comparer les températures entre les données réelles et la planification afin d'évaluer la pertinence de l'approche (et plus particulièrement des modèles).

Nous pouvons décrire le problème de planification de la manière suivante :

$$\mathbf{u}_1^* = \operatorname{argmin}_{\mathbf{u} \in [0,1]^H} \sum_{k=0}^{H-1} \frac{u_1[k]}{H} \quad (4)$$

avec $\begin{cases} y[k+1] = f_\theta(y[k], u_1[k], u_2[k]) \\ y[0] = T_{deb}, y[H-1] \leq T_{fin} \end{cases}$

Cette planification se base donc sur une modélisation à un pas défini par la fonction $f_\theta(\cdot)$ avec la température du bassin représentée par $y[k]$, la variable de contrôle (vanne 3 voies) $u_1[k]$ et les variables exogènes $u_2[k]$. Cette planification est contrainte par une température de départ extraite du jeu de données T_{deb} et la température finale T_{fin} représentant la température nécessaire à l'ouverture de la piscine. Notre analyse sera restreinte à un seul bassin en utilisant les deux modèles sélectionnés précédemment (LSS et NLARX).

À partir des méthodes présentées précédemment, nous pouvons évaluer les deux modèles (avant de réaliser la planification) sur les données de test sélectionnées en tronçon de données (environ 5 jours d'apprentissage et 1 jour de test). Les résultats de prédiction sont visibles sur la figure 3. Ces prédictions récursives sont recalibrées toutes les 8 heures (trait rouge). On peut y voir une bien meilleure précision du modèle non linéaire avec une erreur moyenne sur un horizon de prédiction de 8 heures de 0,04 contre 0,08 pour le modèle linéaire (valeur normalisée).

À partir de ces résultats, il semble intéressant d'utiliser le modèle non linéaire qui offre des performances supérieures. L'étape suivante consiste à utiliser ces deux modèles pour faire la planification. Cette planification va être réalisée sur des données proches de celles du jeu d'entraînement, mais ayant été piloté différent. Ce pilotage a permis, dans cette période, de faire descendre la température la nuit pour économiser de l'énergie. Ces données vont être utilisées comme référence pour comparer les planifications basées sur les modèles à la réalité. Le processus d'optimisation de cette planification décrit par l'équation 4 est optimisé à l'aide du solveur IPOPT.

La figure 4 représente les deux planifications obtenues avec les modèles linéaires et non linéaires, comparées aux vraies données. Pour la planification linéaire, on peut voir une planification proche des données réelles avec une descente de température et une remontée qui correspondent aux données réelles, avec des estimations de chauffage légèrement biaisées par la non-linéarité de la V3V et du circuit de chauffe. Le modèle non linéaire, quant à lui, produit une planification totalement incohérente avec une température qui ne semble pas chuter en dessous de 30 degrés. L'impact de l'ajout d'eau froide est toujours modélisé, mais les déperditions de chaleur sont omises par le modèle. Utiliser cette planification peut être dangereux, car le modèle ne juge pas nécessaire d'ouvrir la V3V pour maintenir la température.

Ce comportement avec le modèle non linéaire peut être expliqué par des données d'entraînement ne contenant pas de basses températures. Le réseau de neurones a tendance à procéder à un raccourci d'apprentissage (*shortcut learning*) [6] qui implique une dynamique stable de la température autour de son point de fonctionnement.

Cet exemple cherche à montrer la pertinence d'un modèle précis mais également cohérent, avec une bonne compréhension des liens de cause à effet. Le modèle linéaire est donc ici supérieur, mais souffre de biais qui ne peuvent être corrigés à cause de sa faible expressivité. Ces biais vont ainsi impacter les performances du pilotage. À l'état actuel, un modèle dirigé par les données ne semble pas suffisant pour répondre à notre problématique.

4 Jeu de données étalon

Nous venons de montrer l'importance d'avoir des modèles cohérents et pouvant obtenir de bonnes interpolations malgré des distributions de données faibles. Afin d'aider la communauté à travailler sur ce problème, nous proposons un jeu de données de la piscine présentée précédemment. Ce jeu de données est introduit avec des critères permettant l'évaluation de la précision de l'horizon de prédiction, ainsi que les capacités de prédiction. Les données sont accessibles avec le lien suivant : <https://benchmark-datadriven-sysid.purecontrol.com/>.

4.1 La sélection des données et son contexte

Nous proposons une période de collecte allant de septembre 2019 à l'été 2020. Cette période de données comprend une

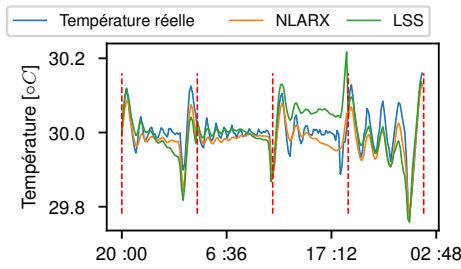


FIGURE 3 – Prédiction sur un horizon de 8h avec données de test (bassin loisir).

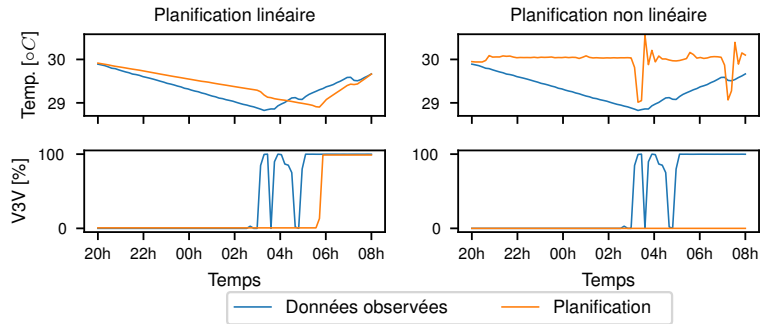


FIGURE 4 – Résultat de planification de la température à partir de modèles dirigés par les données.




FIGURE 5 – Données d’extrapolation.

période de fermeture de la piscine dans le cadre des mesures anti-COVID ainsi que deux stratégies de pilotage différentes pour les deux bassins, ce qui offre plus d’hétérogénéité pour les algorithmes d’apprentissage.

Dans le cadre de notre proposition, nous avons pré-découpé les zones d’intérêt en filtrant les périodes avec des anomalies de fonctionnement ou des données manquantes. La période du COVID avec une mise en veille du système est retirée du jeu d’entraînement et gardée pour les scénarios d’extrapolation.

Nous introduisons les scénarios d’extrapolation comme des périodes dans les données où le système est manipulé de manière différente du jeu d’entraînement. Cette différence se traduit principalement par des distributions de température des bassins loin des distributions observées. Les scénarios sont des périodes de 1 à plusieurs jours consécutifs. Quatre scénarios sont proposés pour l’évaluation en extrapolation. Une comparaison entre un extrait de données d’apprentissage et deux scénarios pour le premier bassin est visible figure 5. On peut décrire tous ces scénarios de la manière suivante :

- Vanne 3 voies natation bloquée à 50%.
- Bassin loisir refroidi pour le confinement de mars 2020.
- Bassin natation refroidi pendant le confinement.
- Montée en température pour la réouverture post-confinement.

Concernant le jeu de données en lui même, il est discrétisé à un pas de 10 minutes avec une filtration des erreurs de mesure. Les données sont déjà séparées entre test et entraînement avec une cohérence temporelle pour éviter les fuites de données.

4.2 Les critères d’évaluation

Afin d’évaluer les modèles, nous proposons plusieurs critères d’évaluation ayant pour objectif de caractériser la pré-

cision et les capacités de prédiction, en accord avec les observations précédentes et nos besoins pour le contrôle.

Notre critère de prédiction repose sur la précision d’un horizon de prédiction de 8 heures. Ces prédictions sont réalisées en connaissant les variables exogènes dans le futur et l’état courant du système. On peut regrouper les différents critères de précision par la formule suivante :

$$\mathcal{L}(I, J) = \frac{1}{J + I - 1} \sum_{i=I}^J \sqrt{\frac{\sum_{k=0}^K \|\hat{y}[i+k|k] - y[i+k]\|_2^2}{K}} \quad (5)$$

Avec $\hat{y}[i+k|k]$, la prédiction sachant l’observation à l’instant k de l’état du système et des variables exogènes de l’instant k à $k+i$. $y[i+k]$ représente le vecteur de température à l’instant $i+k$. La formule 5 représente la précision moyenne de notre modèle du pas I à J de l’horizon de précision. Cette fonction permet d’obtenir la précision de notre modèle suivant différentes sections de l’horizon. On peut ainsi proposer les trois critères d’évaluation suivants, $\mathcal{L}(1, H/4)$, $\mathcal{L}(1, H)$ et $\mathcal{L}(3H/4, H)$ représentant respectivement la précision moyenne sur l’horizon visé, la précision à court terme et à long terme. En plus de ces critères, nous pouvons pour chaque scénario d’extrapolation ajouter le critère $\mathcal{L}(1, H)$ pour chacun d’entre eux afin d’obtenir sept critères.

Afin d’aider la communauté à manipuler les données, en plus d’être mis à disposition, deux interfaces Python et Matlab sont disponibles afin de disposer de ces critères d’évaluations.

4.3 Résultats

À partir des critères que nous avons présenté précédemment ainsi que des modèles de l’état de l’art que nous avons sélectionné, nous pouvons introduire leur résultat sur notre tâche de modélisation. Ces résultats sont obtenus avec les modèles introduits dans la section état de l’art.

Le premier graphique présenté figure 6 représente l’erreur des deux modèles sur l’horizon de prédiction choisi. Cette figure met en évidence une nette supériorité du modèle non linéaire pour la prédiction du bassin 2. L’intérêt du modèle non linéaire est d’autant plus forte sur les prédictions long terme par rapport au modèle linéaire.

Viennent ensuite les critères d’évaluation pour ces deux

	$\mathcal{L}(1, H)$	$\mathcal{L}(1, H/4)$	$\mathcal{L}(3H/4, H)$	S1 $\mathcal{L}(1, H)$	S2 $\mathcal{L}(1, H)$	S3 $\mathcal{L}(1, H)$	S4 $\mathcal{L}(1, H)$
LSS	0.32	0.11	0.52	0.29	0.49	0.88	0.36
NLARX	0.23	0.10	0.31	0.22	0.60	1.24	1.45

TABLE 1 – Erreur de prédiction suivant les critères proposés (Si = Scénario i).

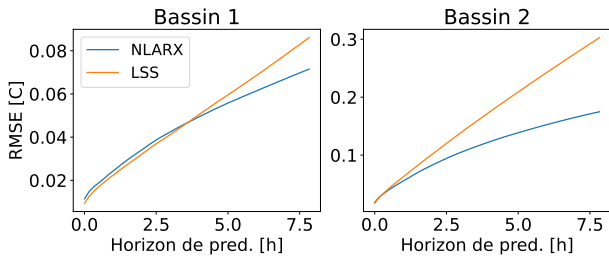


FIGURE 6 – Précision moyenne suivant l'horizon de prédiction (par bassin).




FIGURE 7 – Prédiction de 48 pas sur les données de test.

approches suivant les sept critères développés plus tôt. La table 1 regroupe les résultats pour les deux modèles. Comme attendu, la précision du modèle non linéaire sur les données de tests est meilleure que celle du modèle linéaire sur les 3 critères. Le modèle linéaire reprend son avantage dans l'extrapolation avec des résultats bien meilleurs sur la majorité des scénarios d'extrapolation.

La figure 7 présente un extrait des prédictions des deux modèles sur un ensemble de données test. Les lignes verticales rouges symbolisent la recalibration des modèles en fonction des observations. On observe une meilleure précision du modèle non linéaire, en particulier durant les périodes de baisse de température pour le premier bassin.

La figure 8 met en évidence les résultats de prédiction correspondant au scénario d'extrapolation numéro 4. Dans ce cas, les modèles sont évalués durant une période de hausse de température des bassins. Le modèle linéaire affiche un comportement adéquat, tandis que le modèle non linéaire génère une prédiction contre-intuitive, indiquant un refroidissement en plein épisode de réchauffement. Ce comportement remet en question la capacité de généralisation du réseau de neurones pour des distributions d'entrée éloignées de celles utilisées lors de l'apprentissage. Bien que l'ensemble de données soit nettement plus grand (plusieurs mois) que dans la section 3, il demeure trop restreint en termes de distribution pour proposer un modèle capable de généraliser de manière satisfaisante.

Ces résultats illustrent les limites des approches classiques à proposer une modélisation capable d'extrapoler convenablement tout en proposant une expressivité pouvant délivrer




FIGURE 8 – Prédiction de 48 pas sur le scénario 4.

sur les données d'interpolation une précision la plus fine possible.

5 Conclusion et perspective

Dans un contexte où la gestion de l'énergie devient critique, l'optimisation des systèmes par une approche de modélisation dirigée par les données a été faite. Cette idée est illustrée ici dans le contexte de pilotage de la température des bassins d'une piscine publique.

Un jeu de données de la piscine est mis à disposition de la communauté comme cas concret de modélisation dirigée par les données dans un contexte de pilotage. Les difficultés de la modélisation de ce système à des fins de contrôle ont été présentées afin de rendre compte des spécificités de ce problème. Afin de pouvoir comparer les méthodes dans ce contexte, des critères de performance ont été formulés.

Des approches non spécifiques ont été utilisées afin de rendre compte de performances de référence dans ce contexte. Le modèle linéaire choisi offre de bonne performance d'extrapolation, mais a une précision sur les données de test perfectible. À l'inverse, le modèle non linéaire obtient de bonnes performances sur les données de tests, mais n'est pas capable de produire de bons résultats d'extrapolation.

Des approches plus spécifiques sont donc nécessaires pour améliorer les résultats obtenus et proposer ainsi une méthode basée sur les données plus performante. Une extension naturelle consiste à utiliser des connaissances a priori simples et peu coûteuses (car ne nécessitant pas d'expertise spécifique). On peut notamment envisager des approches dites "physics-informed" [22]. Une autre idée, orthogonale à la première, serait d'exploiter l'état de l'art sur l'estimation de l'incertitude épistémique [2] afin de détecter ces fonctionnements d'extrapolation pour proposer des contre-mesures. Toutes ces pistes peuvent être explorées en utilisant le benchmark proposé.

Une extension prévue de ces travaux consiste à utiliser les algorithmes prédictifs de contrôle avec ces modèles basés sur les données. Cela permettrait non seulement de mettre

davantage en évidence la problématique d'extrapolation de modèle, mais également de rendre l'évaluation des méthodes d'apprentissage plus directe.

Références

- [1] Deep Reinforcement Learning for Building HVAC Control. *Proceedings - Design Automation Conference*, Part 12828, 2017.
- [2] Moloud Abdar, Farhad Pourpanah, Sadiq Hussain, Dana Rezazadegan, Li Liu, Mohammad Ghavamzadeh, Paul Fieguth, Xiaochun Cao, Abbas Khosravi, U. Rajendra Acharya, Vladimir Makarevich, and Saeid Nahavandi. A review of uncertainty quantification in deep learning : Techniques, applications and challenges. *Information Fusion*, 76 :243–297, 2021.
- [3] Francesco Calise, Rafal Damian Figaj, and Laura Vanoli. Energy and economic analysis of energy savings measures in a swimming pool centre by means of dynamic simulations. *Energies*, 11(9), sep 2018.
- [4] Yujiao Chen, Zheming Tong, Yang Zheng, Holly Samuelson, and Leslie Norford. Transfer learning with deep neural networks for model predictive control of hvac and natural ventilation in smart buildings. *Journal of Cleaner Production*, 254 :119866, 2020.
- [5] Mohamad Fadzli Haniff, Hazlina Selamat, Rubiyah Yusof, Salinda Buyamin, and Fatimah Sham Ismail. Review of hvac scheduling techniques for buildings towards energy-efficient and cost-effective operations. *Renewable and Sustainable Energy Reviews*, 27 :94–103, 2013.
- [6] Robert Geirhos, Jörn Henrik Jacobsen, Claudio Michalelis, Richard Zemel, Wieland Brendel, Matthias Bethge, and Felix A. Wichmann. Shortcut learning in deep neural networks. *Nature Machine Intelligence*, 2(11) :665–673, 2020.
- [7] R. B. Gopaluni, R. S. Patwardhan, and S. L. Shah. Mpc relevant identification - tuning the noise model. *Journal of Process Control*, 14(6) :699–714, 2004.
- [8] Yantong Li, Natasa Nord, Nan Zhang, and Cheng Zhou. An ann-based optimization approach of building energy systems : Case study of swimming pool. *Journal of Cleaner Production*, 277, 12 2020.
- [9] L. Ljung. *System Identification : Theory for the User*. Pearson Education, 1998.
- [10] Jingran Ma, S. Joe Qin, Bo Li, and Tim Salsbury. Economic model predictive control for building energy systems. In *ISGT 2011*, pages 1–6, 2011.
- [11] Jingran Ma, S. Joe Qin, Bo Li, and Tim Salsbury. Economic model predictive control for building energy systems. 2011.
- [12] José Pablo Delgado Marín and José R. García-Cascales. Dynamic simulation model and empirical validation for estimating thermal energy demand in indoor swimming pools. *Energy Efficiency*, 13 :955–970, 2020.
- [13] J. P. Delgado Marín, F. Vera García, and J. R. García Cascales. Use of a predictive control to improve the energy efficiency in indoor swimming pools using solar thermal energy. *Solar Energy*, 179 :380–390, 2019.
- [14] A. Mechaqrane and M. Zouak. A comparison of linear and neural network arx models applied to a prediction of the indoor temperature of a building. *Neural Computing & Applications*, 13(1) :32–37, Apr 2004.
- [15] David I. Mendoza-Serrano and Donald J. Chmielewski. Smart grid coordination in building hvac systems : Empc and the impact of forecasting. *Journal of Process Control*, 24(8) :1301–1310, 2014. Economic nonlinear model predictive control.
- [16] John Murphy and Neil Maldeis. Using time-of-day scheduling to save energy. *ASHRAE Journal*, 51 :42+, May 2009.
- [17] Vesna M Ranković and Ilija Ž Nikolić. Identification of nonlinear models with feed forward neural network and digital recurrent network. *FME Transactions*, 36(2) :87–92, 2008.
- [18] Antônio H. Ribeiro and Luis A. Aguirre. Shooting Methods for Parameter Estimation of Output Error Models. volume 50, pages 13998–14003. Elsevier B.V., jul 2017.
- [19] Johan Schoukens and Lennart Ljung. Nonlinear system identification : A user-oriented road map. *IEEE Control Systems Magazine*, 39(6) :28–99, 2019.
- [20] R. Sendra-Arranz and A. Gutiérrez. A long short-term memory artificial neural network to predict daily hvac consumption in buildings. *Energy and Buildings*, 216 :109952, 2020.
- [21] Matt Wallace, Ryan McBride, Siam Aumi, Prashant Mhaskar, John House, and Tim Salsbury. Energy efficient model predictive building temperature control. *Chemical Engineering Science*, 69(1) :45–58, 2012.
- [22] Jared Willard, Xiaowei Jia, Shaoming Xu, Michael Steinbach, and Vipin Kumar. Integrating scientific knowledge with machine learning for engineering and environmental systems. *ACM Comput. Surv.*, 55(4), nov 2022.
- [23] Nikita Zemtsov, Jaroslav Hlava, Galina Frantsuzova, Henrik Madsen, Rune Gronborg Junker, and John Bagterp Jorgensen. Economic MPC based on LPV model for thermostatically controlled loads. In *2017 International Siberian Conference on Control and Communications, SIBCON 2017 - Proceedings*. Institute of Electrical and Electronics Engineers Inc., jul 2017.
- [24] Zhengbo Zou, Xinran Yu, and Semiha Ergan. Towards optimal control of air handling units using deep reinforcement learning and recurrent neural network. *Building and Environment*, 168 :106535, 2020.