

Prédiction des paramètres de modèles RC de bâtiments par réseaux de neurones à partir de caractéristiques simples du bâtiment.

Antoine DUMONT^{1*}, Véronique FELDHEIM¹, Paul LYBAERT¹

¹ Service de Thermique et Combustion, Faculté Polytechnique de Mons, Université de Mons
Rue de l'Épargne, 56 - 7000 Mons

*(auteur correspondant : antoine.dumont@umons.ac.be)

Résumé - Le secteur du bâtiment représente une part significative de la consommation énergétique et des émissions de gaz à effet de serre, principalement liées au chauffage. La modélisation thermique simplifiée des bâtiments permet d'évaluer rapidement ces besoins énergétiques. Ce travail explore l'utilisation de modèles "boîte grise" basés sur un schéma 4R3C en combinaison avec un réseau de neurones pour estimer les paramètres thermiques résistances-capacités (RC) à partir de caractéristiques géométriques simples des bâtiments. Une base de données de 640 configurations géométriques a été générée par simulation TRNSYS et utilisée pour identifier les paramètres RC. Un sous-ensemble de ces données a servi à l'apprentissage d'un réseau de neurones multi-couches. Le modèle entraîné est ensuite utilisé pour prédire les paramètres RC de configurations géométriques inédites, non vues lors de l'apprentissage, afin d'évaluer sa capacité de généralisation. Les résultats montrent que le réseau est capable de prédire les résistances et capacités pour ces configurations nouvelles. De plus, une comparaison avec les paramètres issus de l'identification classique met en évidence une amélioration globale des prédictions, le réseau réduisant les écarts par rapport aux valeurs théoriques pour la majorité des paramètres. Le modèle permet ainsi de générer des paramètres RC physiquement cohérents sans recourir à de nouvelles simulations détaillées. Cette approche permet la génération rapide de modèles thermiques simplifiés et l'estimation des besoins énergétiques à partir de caractéristiques simples du bâtiment.

Nomenclature

C	Capacité thermique, J/K	<i>Indices et exposants :</i>	
EQM	Erreur Quadratique Moyenne	<i>ground</i>	sol
FIT	Indice de qualité d'ajustement (%)	<i>heat</i>	chaud
i	Indice temporel	<i>in</i>	intérieur
N	Nombre de pas de temps	<i>inf</i>	infiltration
$\dot{Q}$	Flux de chaleur, W	n	nœud
R^2	Coefficient de détermination	<i>op</i>	opaque
R	Résistance thermique, K/W	<i>out</i>	extérieur
$REQM$	Racine de l'EQM	<i>vent</i>	ventilation
RN	Réseau de neurones	<i>win</i>	fenêtres
T	Température, K		

1. Introduction

Le secteur du bâtiment représente environ 40 % de la consommation énergétique finale en Europe et près d'un tiers des émissions de gaz à effet de serre, principalement liées au chauffage [1, 2]. Cette situation est aggravée par l'ancienneté du parc immobilier et des niveaux d'isolation souvent insuffisants. Dans ce contexte, la modélisation énergétique des bâtiments joue un rôle central pour l'estimation rapide des besoins thermiques. Les modèles "boîte grise" basés sur des schémas résistances-capacités (RC) offrent

un compromis pertinent entre interprétabilité physique, précision et temps de calcul, se situant entre les approches “boîte blanche” et “boîte noire”. Ce travail s’inscrit dans le cadre du projet Integrated Local Energy System (ILES) [3] et vise à prédire les paramètres RC de bâtiments à partir de caractéristiques géométriques simples, en combinant simulation thermique et apprentissage automatique.

2. Méthodologie

La méthodologie de ce travail repose sur l’utilisation de modèles thermiques “boîte grise” basés sur des schémas RC. Contrairement au travail antérieur [4] ayant exploré et comparé différentes topologies RC, ce travail se concentre exclusivement sur le modèle 4R3C (Figure 1), dont la capacité à prédire simultanément la température intérieure et les besoins en chauffage a déjà été démontrée. L’approche adoptée s’articule autour de quatre étapes principales : la génération de données de référence à l’aide de simulations détaillées sous TRNSYS ; l’identification et l’estimation des paramètres thermiques du modèle ; la génération d’une base de données paramétrique ; et l’utilisation de cette base de données pour l’apprentissage d’un réseau de neurones et la prédiction de paramètres RC.




Figure 1 : Modélisation d’un bâtiment basée sur le schéma 4R3C [4].

2.1. Simulation du bâtiment avec TRNSYS

En l’absence de données expérimentales suffisantes, le logiciel TRNSYS, outil de référence pour la simulation thermique dynamique des bâtiments [5], est utilisé afin de générer les données nécessaires à l’identification et à la validation du modèle RC. Le bâtiment de référence est un bâtiment fictif mono-zone de type lourd (Figure 2), d’une surface au sol de 150 m² (rapport longueur/largeur = 1), d’une hauteur de 3 m et doté d’une toiture plate. La surface vitrée totale est de 22,5 m² (15 % de la surface au sol), répartie sur les façades avant et latérales et modélisée par un double vitrage à châssis bois, avec une orientation globale de 225°.



Figure 2 : Bâtiment administratif mono-zone fictif [4].

Les simulations utilisent les données météorologiques de la station d’Uccle (température extérieure et rayonnement solaire), la température du sol étant supposée constante à 10 °C. Afin de solliciter de façon adéquate l’ensemble des paramètres du modèle RC, l’année est découpée en quatre périodes alternant entre régime libre et régime avec contrôle de la température intérieure. Lors des régimes de contrôle, la température de consigne est fixée à 15 °C en période d’inoccupation et à 22 °C en période d’occupation. Les apports internes et le refroidissement ne sont pas considérés. Les infiltrations sont fixées à 0,24 h⁻¹, tandis que la ventilation mécanique dépend de l’occupation. Les simulations fournissent, à un pas de temps horaire, la température intérieure, les flux de chauffage, les apports solaires ainsi que les flux de ventilation et d’infiltration, utilisés comme données de référence pour l’identification du modèle RC.

2.2. Identification de système et estimation des paramètres

L'identification des paramètres constitue une étape clé permettant de relier la structure théorique du modèle RC au comportement thermique réel du bâtiment. Dans ce cadre, les résistances et capacités thermiques sont estimées à partir des données générées par TRNSYS en utilisant la technique d'identification de système. De manière générale, l'identification de systèmes vise à construire des modèles dynamiques à partir de données d'entrée et de sortie. Cette approche consiste donc à ajuster les paramètres thermiques de façon à minimiser l'écart entre la température intérieure simulée par le modèle RC et celle issue de la simulation de référence. Dans ce travail, l'identification est réalisée à l'aide de la *System Identification Toolbox* de Matlab [6]. L'identification repose sur la minimisation de l'erreur quadratique moyenne (EQM), définie comme :

$$EQM = \frac{1}{N} \sum_{i=1}^N (T_{in, RC}(i) - T_{in, TRNSYS}(i))^2 \quad (1)$$

L'algorithme d'optimisation utilise une stratégie "automatique" qui sélectionne à chaque itération la direction de descente la plus efficace parmi plusieurs méthodes numériques, notamment Gauss-Newton, Levenberg-Marquardt, Gauss-Newton adaptatif et des approches basées sur le gradient. L'optimisation est arrêtée lorsque l'amélioration relative de la fonction de coût devient inférieure à 10^{-6} ou lorsque le nombre maximal d'itérations (500) est atteint. Afin de garantir des valeurs physiquement cohérentes, des contraintes de non-négativité sont imposées sur les paramètres. La qualité de l'identification est évaluée à l'aide d'un indicateur de type *FIT*, exprimé en pourcentage, permettant de quantifier la capacité du modèle à reproduire la dynamique thermique du bâtiment. Une fois les paramètres identifiés, ceux-ci sont comparés aux valeurs théoriques attendues issues des données du bâtiment.

$$FIT = 100 \times \left(1 - \frac{\|T_{in, TRNSYS} - T_{in, RC}\|}{\|T_{in, TRNSYS} - \text{mean}(T_{in, TRNSYS})\|} \right) \quad (2)$$

2.3. Génération d'une base de données paramétrique

Afin de permettre l'exploitation des modèles RC à grande échelle sans recourir systématiquement à une étape d'identification des paramètres, une base de données paramétrique est constituée à partir de simulations TRNSYS et d'identifications successives des modèles RC. L'objectif est d'établir des relations explicites entre des caractéristiques géométriques simples des bâtiments et les paramètres thermiques équivalents des modèles RC.

Pour ce faire, un ensemble de paramètres clés décrivant la géométrie et l'implantation du bâtiment est sélectionné. Les paramètres étudiés et leurs plages de variation sont les suivants :

- **Surface au sol** : 50, 75, 100, 125, 150 et 200 m² ;
- **Ratio surface vitrée / surface au sol** : 5, 10, 15, 20 et 30 % ;
- **Rapport largeur/profondeur** : 1, 2 et 4 ;
- **Orientation** : 0°, 45°, 90°, 135°, 180°, 225°, 270° et 315°.

Parmi l'ensemble des combinaisons possibles, 640 configurations sont sélectionnées de manière aléatoire. Chaque configuration correspond à un bâtiment mono-zone de type lourd présentant des caractéristiques identiques d'enveloppe et de vitrage et simulé sous TRNSYS selon la méthodologie décrite précédemment. Pour chacune d'elles, les données obtenues par simulation sont utilisées pour identifier les paramètres thermiques du modèle 4R3C par une procédure d'identification de système. Les paramètres RC identifiés sont ensuite associés aux caractéristiques géométriques correspondantes du bâtiment. L'ensemble de ces couples entrée-sortie constitue une base de données paramétrique servant pour l'apprentissage pour le réseau de neurones.

2.4. Apprentissage d'un réseau de neurones et prédiction de paramètres RC

Avant l'apprentissage, l'ensemble des variables d'entrée et de sortie est normalisé afin d'améliorer la convergence du processus d'optimisation et d'assurer une pondération équitable des grandeurs manipulées. L'apprentissage est réalisé de manière supervisée à l'aide d'un réseau de neurones multi-couches de type perceptron (MLP) [7, 8].

Le réseau comprend une couche d'entrée (caractéristiques géométriques du bâtiment), une ou plusieurs couches cachées et une couche de sortie fournissant directement les paramètres thermiques R et C . Les poids et biais sont ajustés de manière à minimiser l'écart entre les paramètres identifiés et ceux prédits par le modèle.

L'architecture du réseau (nombre de couches et de neurones) ainsi que les hyperparamètres associés (algorithme d'optimisation et régularisation) sont déterminés par validation croisée via une recherche sur grille [9, 10]. L'espace de recherche inclut plusieurs architectures (une à trois couches cachées), différents niveaux de régularisation ($\alpha \in \{10^{-4}, 10^{-3}, 10^{-2}\}$) et deux solveurs (Adam et L-BFGS). Le critère d'optimisation retenu est le coefficient de détermination $\mathcal{R}^2$.

L'architecture optimale retenue comporte deux couches cachées de 20 et 10 neurones, avec un solveur Adam et un terme de régularisation $\alpha = 0,001$. Ce choix correspond à un compromis entre capacité de modélisation et limitation du surapprentissage, assurant de bonnes performances de généralisation. Une fois entraîné, le réseau est utilisé comme méta-modèle pour prédire les paramètres RC de nouvelles configurations de bâtiments, sans recourir à des simulations détaillées ni à une procédure d'identification.

3. Résultats

Cette section présente les résultats obtenus pour le modèle 4R3C. Les résultats sont organisés en quatre parties : la simulation de référence réalisée sous TRNSYS, servant de base à l'identification ; l'identification du modèle 4R3C sur le bâtiment de référence ; l'analyse des résultats issus de la génération de la base de données paramétrique ; et l'évaluation des performances du modèle d'apprentissage automatique, utilisé pour prédire directement les paramètres RC à partir de caractéristiques géométriques simples.


3.1. Simulation de référence sous TRNSYS

La simulation TRNSYS constitue la référence utilisée pour l'identification et la validation du modèle RC. Le bâtiment fictif mono-zone est simulé sur une année complète à l'aide des données météorologiques d'Uccle. Afin de solliciter l'ensemble des paramètres thermiques, l'année est découpée en quatre périodes alternant régimes de température intérieure libre (premier et troisième trimestres) et phases avec contrôle de celle-ci (deuxième et quatrième trimestres). Sur l'ensemble de l'année, la température intérieure atteint un maximum de $25,3^\circ\text{C}$ en régime libre, tandis que la puissance de chauffage maximale s'élève à $20,7\text{ kW}$ lors des périodes les plus contraignantes. Le besoin annuel de chauffage est estimé à $16,3\text{ MWh}$. Ces résultats sont illustrés à la Figure 3.


3.2. Identification et validation du modèle 4R3C

L'identification du modèle 4R3C a été réalisée à partir des données TRNSYS interpolées à un pas de temps de 15 minutes. Seule la température intérieure est utilisée comme variable de sortie, tandis que les autres données (chauffage, ventilation, infiltrations et apports solaires) sont considérées comme entrées du modèle. Le modèle identifié reproduit de manière satisfaisante la dynamique thermique du bâtiment. L'indice de fitting sur la température intérieure atteint 79% , suffisant pour suivre l'évolution temporelle de la température intérieure, tant en régime libre qu'en régime contrôlé.

Une analyse des valeurs identifiées (Tableau 1) montre que les paramètres ont été correctement estimés par rapport aux valeurs théoriques. Les écarts peuvent s'expliquer par le fait que l'identification repose uniquement sur la température intérieure T_{in} , sans accès aux températures des nœuds intermédiaires (T_2 ,



(a) Évolution de la température intérieure.



(b) Évolution de la demande de chauffage.

Figure 3 : Résultats de la simulation TRNSYS pour le bâtiment fictif.

T_3). Les résistances thermiques restent globalement proches des ordres de grandeur théoriques, avec des écarts inférieurs à 40 %.

Tableau 1 : Comparaison des valeurs estimées du modèle 4R3C et théoriques pour le bâtiment fictif mono-zone simulé.

Paramètre	Valeur théorique	Valeur identifiée	Écart (%)
$R_1 + R_3$ [K/W]	0,0096	0,0105	-8,7
$R_2 + R_4$ [K/W]	0,0277	0,0444	-37,7
C_1 [MJ/K]	1,9	2,7	-30,8
C_2 [MJ/K]	6,3	22,9	-72,4
C_3 [MJ/K]	54,2	98,4	-45

La validation porte également sur les besoins en chauffage. Malgré sa structure simplifiée, le modèle 4R3C reproduit correctement les profils horaires et le besoin annuel (voir Figure 4), avec une erreur relative, en valeur absolue, de 0,9 % sur la puissance de chauffage maximale et une erreur relative, en valeur absolue, de 0,2 % sur l'énergie annuelle de chauffage (voir Tableau 2). La figure 4 confirme que la dynamique générale est correctement capturée.




Figure 4 : Validation du modèle 4R3C : comparaison entre la référence TRNSYS et le modèle RC identifié pour la température intérieure et la demande de chauffage.

3.3. Résultats de la base de données paramétrique

La base de données paramétrique est construite à partir des 640 configurations de bâtiments simulées et identifiées. Celles-ci correspondent toutes à des bâtiments présentant une composition d'enveloppe

Tableau 2 : Indicateurs de performance pour le modèle 4R3C dans le cas du bâtiment fictif.

Variable	Valeur
REQM T_{in} [°C]	1,3
Erreur relative sur $\dot{Q}_{heat,max}$ [%]	0,9
Erreur relative sur $\dot{Q}_{heat,total}$ [%]	0,2
FIT T_{in} [%]	79,7
FIT $\dot{Q}_{heat}$ [%]	88,4

identique, seules les caractéristiques géométriques (surface au sol, compacité, ratio de surface vitrée et orientation) variant entre les cas. Le modèle 4R3C montre globalement de bonnes performances d'ajustement, avec environ 75 % des configurations (499 cas) présentant un coefficient de fitting supérieur à 75 % sur la température intérieure (Tableau 3).

Tableau 3 : Distribution du nombre de configurations selon les intervalles de fitting sur T_{in} pour le modèle 4R3C.

< 0%	0–100%	> 50%	> 75%	> 90%
36	604	576	499	261

L'analyse des écarts relatifs entre les paramètres identifiés et les valeurs théoriques (Tableau 4) montre que les résistances thermiques sont globalement bien estimées et physiquement cohérentes. Les capacités présentent une variabilité plus marquée, en particulier celles associées à l'enveloppe, en raison de leur sensibilité aux variations géométriques et des limites d'une identification basée sur la seule température intérieure. Ces observations mettent en évidence la nécessité de filtrer les configurations les plus fiables afin de garantir la qualité des données utilisées pour les étapes ultérieures de modélisation.

Tableau 4 : Distribution du nombre de configurations selon les écarts relatifs Δ entre paramètres identifiés et valeurs théoriques (modèle 4R3C).

Paramètre	Δ [%]				
	[-100 : -50[	[-50 : 0[	[0 : 50]	]50 : 100]	]100 : ∞[
$R_1 + R_3$	5	627	8	0	0
$R_2 + R_4$	107	288	239	6	0
C_1	110	528	2	0	0
C_2	344	209	27	18	42
C_3	150	249	241	0	0

3.4. Apprentissage du réseau de neurones et prédiction des paramètres RC

Un réseau de neurones multi-couches est entraîné afin d'établir une relation directe entre les paramètres géométriques du bâtiment (surface au sol, rapport largeur/profondeur, ratio vitré et orientation) et les paramètres thermiques du modèle RC. Afin de garantir la qualité des données utilisées pour l'apprentissage, seules les configurations satisfaisant simultanément un coefficient de fitting supérieur à 90 % et des écarts relatifs sur les paramètres RC inférieurs à ± 50 % sont retenues. Ce filtrage conduit à un sous-ensemble de 139 configurations (21,7 % des 640 configurations simulées et identifiées) utilisé pour l'entraînement du réseau de neurones, en écartant les cas présentant une identification du modèle RC jugée non suffisamment fiable.

Afin d'évaluer la capacité de généralisation du modèle une fois entraîné, un ensemble élargi de 720 configurations est considéré, obtenu en faisant varier les paramètres géométriques (orientation, surface au sol, ratio de surface vitrée et rapport longueur/largeur). Parmi celles-ci, 139 correspondent à des cas

d'apprentissage. Les 581 autres configurations dédiées à l'évaluation du réseau comprennent 501 cas issus de la base initiale identifiée avec TRNSYS, mais non utilisés lors de l'entraînement, ainsi que 80 configurations entièrement inédites.

Les performances obtenues sur la base d'apprentissage montrent une excellente concordance entre les paramètres thermiques prédits et les valeurs de référence (excepté pour C_2 indiquant une difficulté à modéliser ce paramètre dans la phase d'apprentissage), confirmant la capacité du réseau à reproduire fidèlement les configurations connues. Cette qualité d'apprentissage est illustrée au Tableau 5a via les coefficients de détermination $\mathcal{R}^2$. Le réseau entraîné est ensuite appliqué aux configurations inédites afin d'évaluer sa robustesse. Les résultats synthétisés au Tableau 5b présentent, pour les 640 configurations simulées et identifiées, le nombre de cas où le réseau de neurones et la méthode d'identification offrent la meilleure estimation des paramètres, en se basant sur l'écart relatif avec la valeur théorique attendue.

Tableau 5 : Synthèse des performances du réseau de neurones (RN) : qualité d'apprentissage via $\mathcal{R}^2$ et capacité de généralisation en comparant avec l'identification classique (ID) sur les 640 configurations.

(a) Qualité d'ajustement ($\mathcal{R}^2$).

Paramètre	$\mathcal{R}^2$
R_1+R_3	0,96
R_2+R_4	0,95
C_1	0,98
C_2	0,5
C_3	0,97

(b) Capacité de généralisation (comparée à ID).

Paramètre	RN	ID
R_1+R_3	357	283
R_2+R_4	410	230
C_1	283	357
C_2	588	52
C_3	441	199

Pour l'ensemble des configurations prédites (720 cas), les résultats (voir Tableau 6) montrent que le réseau de neurones prédit des paramètres RC globalement cohérents et physiquement plausibles, malgré l'absence d'information préalable sur ces configurations. Comme le montre le tableau 6, la majorité des paramètres prédits présente des écarts relatifs en valeur absolue inférieurs à 50 % par rapport aux valeurs de référence. Seuls quelques cas atteignent des écarts plus importants, généralement associés à des paramètres plus sensibles aux variations géométriques.

L'apprentissage automatique permet globalement de réduire les écarts par rapport à une identification classique des paramètres RC, conduisant à des estimations plus stables et physiquement cohérentes sur l'ensemble des configurations testées. Cette tendance, confirmée par la comparaison entre les performances sur données d'apprentissage et sur données de généralisation (tableau 5), met en évidence la capacité du modèle à maintenir de bonnes performances hors échantillon. Ces résultats montrent ainsi que le réseau de neurones ne se limite pas à une interpolation des données d'apprentissage, mais qu'il a appris des relations structurelles robustes entre la géométrie du bâtiment et les paramètres thermiques du modèle RC, ce qui constitue un atout majeur pour l'identification rapide de modèles thermiques dans des contextes réels où les paramètres du système sont généralement inconnus a priori.

Tableau 6 : Distribution des écarts relatifs (Δ) pour le modèle 4R3C. Comparaison entre les paramètres prédits par le réseau de neurones et les valeurs théoriques.

Paramètre	Δ [%]			
	[-100 :-50[	[-50 :0[	[0 :50]	]50 :100]
R_1+R_3	0	505	215	0
R_2+R_4	0	81	597	42
C_1	13	703	4	0
C_2	0	665	55	0
C_3	0	172	543	5

4. Conclusion et perspectives

Ce travail visait à développer une méthodologie permettant de prédire les paramètres RC de bâtiments à partir de caractéristiques géométriques simples, dans le but de générer rapidement des modèles thermiques “boîte grise” fiables. Une base de données paramétrique a été constituée à partir de simulations TRNSYS et d’identifications d’un modèle RC. Après filtrage, un réseau de neurones multi-couches a été entraîné pour établir la relation entre géométrie et paramètres thermiques. Les résultats montrent que le réseau est capable de prédire les résistances et capacités, y compris pour des configurations géométriques inédites, tout en réduisant globalement les écarts observés lors de l’identification classique. Il convient toutefois de souligner que l’identification de système et le réseau de neurones sont complémentaires. L’identification du modèle 4R3C constitue une étape indispensable pour générer une base de données de référence pour le réseau de neurones. Ce réseau est ensuite entraîné avec cette base de données afin d’apprendre la relation entre géométrie et paramètres thermiques. Il vise donc à reproduire le processus d’identification des paramètres. Il agit ainsi comme un méta-modèle de l’identification, permettant de prédire directement les paramètres RC pour de nouvelles configurations sans recourir à la double simulation TRNSYS-identification MATLAB, ce qui conduit à un gain de temps significatif.

Les travaux futurs viseront à élargir la base de données en intégrant des variations dans la composition de l’enveloppe des bâtiments. Cela permettra d’entraîner le réseau sur un spectre plus large de configurations et d’améliorer encore sa capacité de généralisation. À terme, cette approche permettra, à partir de caractéristiques géométriques et constructives simples, de déterminer les paramètres RC associés et d’estimer les besoins en chauffage ainsi que la température intérieure pour des bâtiments résidentiels et tertiaires. Elle pourra également être étendue à des modèles multi-zones et à des analyses à l’échelle urbaine.

Références

- [1] Eurostat, Energy consumption in households (2022).
URL https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Energy_consumption_in_households#Context
- [2] E. Commission, Energy Performance of Buildings Directive (2024).
URL https://energy.ec.europa.eu/topics/energy-efficiency/energy-efficient-buildings/energy-performance-buildings-directive_en
- [3] L. F. et le FTJ en Wallonie, Programmation 2021-2027.
URL <https://europe.wallonie.be/home/programmation-2021-2027/projets-approuves.html>
- [4] A. Dumont, V. Feldheim, P. Lybaert, Développement de modèles basés sur des schémas RC comme outil de cartographie pour les besoins en chaud à l’échelle du bâtiment, 03 June 2025. arXiv:<https://hdl.handle.net/20.500.12907/53504>, doi:10.25855/SFT2025-111.
- [5] M. Magni, F. Ochs, S. de Vries, A. Maccarini, F. Sigg, Detailed cross comparison of building energy simulation tools results using a reference office building as a case study, *Energy and Buildings* 250 (2021) 111260.
- [6] Matlab, System Identification Toolbox.
URL <https://nl.mathworks.com/products/sysid.html>
- [7] DataCamp, Perceptrons multicouches dans l’apprentissage automatique, <https://www.datacamp.com/fr/tutorial/multilayer-perceptrons-in-machine-learning>, consulté en janvier 2026.
- [8] A. Piacoa, Réseaux de neurones : le perceptron multi-couches, <https://apiacoa.org/publications/teaching/nn/MLP.pdf>, poly de cours, consulté en janvier 2026.
- [9] Chiny, Recherche par grille avec validation croisée (gridsearchcv), <https://www.chiny.me/recherche-par-grille-avec-validation-croisee-gridsearchcv-25-22.php>, article en français, consulté en janvier 2026.
- [10] F. Pedregosa, G. Varoquaux, A. Gramfort, et al., Gridsearchcv — documentation scikit-learn, https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html, documentation du module sklearn.model_selection, consulté en janvier 2026.

Remerciements

Les auteurs tiennent à remercier le FEDER et le FTJ en Wallonie pour le financement des travaux de recherche.