

## Projet Recherche Innovation (PRI) 2024-2025

# Prédiction des Ilots de Chaleur Urbains (UHI)



Sous la direction de  
Mindjid MAIZIA

Gabrielle VALLEE

# **Prédiction des Ilots de Chaleur Urbains**

Utilisation de l'intelligence artificielle pour la modélisation des  
zones à forte température

Sous la direction de  
Mindjid MAIZIA

Gabrielle VALLEE

2024-2025

# AVERTISSEMENT

Cette recherche a fait appel à des lectures, enquêtes et interviews. Tout emprunt à des contenus d'interviews, des écrits autres que strictement personnel, toute reproduction et citation, font systématiquement l'objet d'un référencement.

L'auteur (les auteurs) de cette recherche a (ont) signé une attestation sur l'honneur de non plagiat.

# Formation par la recherche, Projet de Recherche Innovation en génie de l'Aménagement et de l'Environnement

La formation au génie de l'aménagement et de l'environnement, assurée par le département aménagement et environnement de l'Ecole Polytechnique de l'Université de Tours, associe dans le champ de l'urbanisme, de l'aménagement des espaces fortement à faiblement anthropisés, l'acquisition de connaissances fondamentales, l'acquisition de techniques et de savoir faire, la formation à la pratique professionnelle et la formation par la recherche. Cette dernière ne vise pas à former les seuls futurs élèves désireux de prolonger leur formation par les études doctorales, mais tout en ouvrant à cette voie, elle vise tout d'abord à favoriser la capacité des futurs ingénieurs à :

- Accroître leurs compétences en matière de pratique professionnelle par la mobilisation de connaissances et de techniques, dont les fondements et contenus ont été explorés le plus finement possible afin d'en assurer une bonne maîtrise intellectuelle et pratique,
- Accroître la capacité des ingénieurs en génie de l'aménagement et de l'environnement à innover tant en matière de méthodes que d'outils, mobilisables pour affronter et résoudre les problèmes complexes posés par l'organisation et la gestion des espaces.

La formation par la recherche inclut un exercice individuel de recherche, le projet de fin d'études (P.F.E.), situé en dernière année de formation des élèves ingénieurs. Cet exercice correspond à un stage d'une durée minimum de trois mois, en laboratoire de recherche, principalement au sein de l'équipe Dynamiques et Actions Territoriales et Environnementales de l'UMR 7324 CITERES à laquelle appartiennent les enseignants-chercheurs du département aménagement.

Le travail de recherche, dont l'objectif de base est d'acquérir une compétence méthodologique en matière de recherche, doit répondre à l'un des deux grands objectifs :

- Développer toute ou partie d'une méthode ou d'un outil nouveau permettant le traitement innovant d'un problème d'aménagement
- Approfondir les connaissances de base pour mieux affronter une question complexe en matière d'aménagement.

**Afin de valoriser ce travail de recherche nous avons décidé de mettre en ligne sur la base du Système Universitaire de Documentation (SUDOC), les mémoires à partir de la mention bien.**

# REMERCIEMENTS

Je remercie mon professeur encadrant, M. Maizia, ainsi que l'ensemble des professeurs du département Aménagement Environnement, dont l'enseignement a marqué et enrichi ces trois années d'études.

Je suis également reconnaissant envers mon père pour son regard avisé et envers mes amis, qui m'ont apporté motivation et bonne humeur tout au long de ce parcours.

Enfin, un immense merci à mon grand frère, dont l'aide a été précieuse tout au long de ce projet. Il a pris de son temps pour m'expliquer, me guider et me transmettre ses connaissances avec patience. Merci.

# Contents

|          |                                                                                  |           |
|----------|----------------------------------------------------------------------------------|-----------|
| <b>1</b> | <b>Introduction</b>                                                              | <b>5</b>  |
| <b>2</b> | <b>État de l'art</b>                                                             | <b>6</b>  |
| 2.1      | Définitions liées aux îlots de chaleur urbains . . . . .                         | 6         |
| 2.1.1    | Îlot de chaleur urbain (UHI) . . . . .                                           | 6         |
| 2.1.2    | Artificialisation des sols . . . . .                                             | 7         |
| 2.1.3    | Albédo . . . . .                                                                 | 8         |
| 2.2      | Définitions liées à l'intelligence artificielle (IA) et leur application aux UHI | 10        |
| 2.2.1    | Réseaux de neurones convolutifs et convolutions . . . . .                        | 10        |
| 2.3      | Méthodes empiriques de mesure . . . . .                                          | 12        |
| 2.4      | Méthodes basées sur l'IA . . . . .                                               | 13        |
| <b>3</b> | <b>Méthode</b>                                                                   | <b>14</b> |
| 3.1      | Création du jeu de données . . . . .                                             | 14        |
| 3.2      | Prétraitement des données . . . . .                                              | 15        |
| 3.3      | Séparation des données . . . . .                                                 | 16        |
| 3.3.1    | Entraînement . . . . .                                                           | 17        |
| 3.3.2    | Validation . . . . .                                                             | 17        |
| 3.3.3    | Test . . . . .                                                                   | 17        |
| 3.3.4    | Répartition des données . . . . .                                                | 18        |
| 3.4      | Architecture du réseau . . . . .                                                 | 18        |
| 3.5      | Pré-entraînement . . . . .                                                       | 20        |
| 3.6      | Entraînement . . . . .                                                           | 21        |
| <b>4</b> | <b>Résultats</b>                                                                 | <b>23</b> |
| 4.1      | Explication des résultats et description . . . . .                               | 23        |
| 4.2      | Les pistes d'amélioration . . . . .                                              | 29        |
| <b>5</b> | <b>Conclusion</b>                                                                | <b>31</b> |
| <b>A</b> | <b>Données complémentaires</b>                                                   | <b>34</b> |

# 1 Introduction

Aujourd'hui, 56 % de la population mondiale, soit 4,4 milliards d'habitants, vivent en ville. Cette tendance devrait s'accroître : selon l'ONU, près de 75 % des quelque 10 milliards d'habitants attendus en 2050 résideront en zones urbaines. Cette urbanisation rapide a des impacts majeurs sur le climat local et la qualité de vie des populations urbaines. Les îlots de chaleur urbains (*Urban Heat Island* UHI) sont des phénomènes climatiques caractérisés par des températures plus élevées dans les zones urbaines que dans les zones rurales, particulièrement amplifiées pendant les vagues de chaleur. Ce phénomène résulte de divers facteurs, tels que les caractéristiques morphologiques des villes, les matériaux utilisés, et le manque de végétation.

Il existe deux approches principales pour étudier les îlots de chaleur urbains : la mesure et la modélisation. Les méthodes empiriques, comme les relevés manuels, l'utilisation de capteurs isolés ou les données météorologiques, sont utiles pour des analyses locales. Cependant, elles présentent plusieurs limites : une couverture souvent restreinte, l'absence de mesures continues, et une faible reproductibilité. Par exemple, certaines conditions de mesure spécifiques ne peuvent être reproduites qu'une seule fois, ce qui complique la comparaison ou l'extrapolation des résultats.

Les approches basées sur le *deep learning* et le *machine learning*, souvent regroupées sous le terme d'intelligence artificielle (IA), permettent de généraliser les connaissances empiriques en exploitant de vastes ensembles de données environnementales. Ces méthodes sont particulièrement efficaces pour identifier des tendances, modéliser les UHI de manière plus complète et analyser rapidement de grandes zones. Cependant, elles présentent des limites : elles nécessitent des volumes importants de données de qualité, une infrastructure informatique performante.

Ce projet vise à créer un modèle de *deep learning* capable, à partir d'une image satellite, de générer une carte de chaleur illustrant les îlots de chaleur urbains. Nous comparons ensuite les performances de ce modèle avec celles des méthodes empiriques. En utilisant des réseaux neuronaux convolutifs (*Convolutional neural network*, CNN) pour analyser les données spatiales, nous cherchons à démontrer que l'IA peut produire des résultats plus rapides, précis et généralisables, tout en identifiant les limites et les axes d'amélioration pour des applications futures.

## 2 État de l'art

### 2.1 Définitions liées aux îlots de chaleur urbains

#### 2.1.1 Îlot de chaleur urbain (UHI)

Selon Valéry Masson [1], chercheur français spécialisé dans l'étude de l'impact du climat urbain sur l'environnement, un îlot de chaleur urbain (UHI) est un phénomène qui se caractérise par une différence de température entre le centre d'une ville et ses périphéries rurales environnantes (Figure 1). Cette différence de température peut atteindre plusieurs degrés, et est généralement plus marquée la nuit. Elle est due à l'accumulation de chaleur dans les zones urbaines, notamment en raison de l'absorption et de la rétention de la chaleur par les matériaux de construction, le manque de végétation, et l'activité humaine.



Figure 1: Illustration des îlots de chaleur urbains (Vallée, 2025)

Le phénomène a été décrit pour la première fois par Luke Howard dans son article de 1818 intitulé « *The Climate of London* » [2] comme la hausse des températures dans les régions urbaines par rapport à ce qui se produit dans les zones rurales. Cependant, c'est dans les années 1960 que les scientifiques ont commencé à utiliser le terme « îlot de chaleur urbain » pour décrire cet effet. Depuis lors, les chercheurs ont étudié les causes et les effets de l'UHI dans de nombreuses villes à travers le monde.

Les UHI ont des effets importants sur la qualité de l'air, la santé publique, et les conditions de vie en milieu urbain. Ils peuvent entraîner une augmentation de la demande d'énergie

pour la climatisation, ce qui peut à son tour augmenter les émissions de gaz à effet de serre et contribuer au changement climatique. Les îlots de chaleur peuvent également aggraver la pollution atmosphérique en favorisant la formation d’ozone et d’autres polluants. Ils peuvent également affecter la santé des populations locales, en particulier les personnes âgées et les enfants, en augmentant le risque de maladies liées à la chaleur, comme les coups de chaleur et les maladies cardiovasculaires.

Selon V. Masson [1], contrairement à ce que l’on pourrait penser, la pollution ne joue quasiment aucun rôle dans l’apparition des îlots de chaleur urbains. Ils sont bien davantage dus à la concentration des bâtiments et à l’imperméabilisation des surfaces. Les épisodes de mauvaise qualité de l’air arrivent souvent en même temps que les problèmes de chaleur, mais ils ne sont pas liés. Les îlots de chaleur urbains ne sont pas des phénomènes climatiques, mais météorologiques, et le vent, la pluie ou les nuages peuvent les réduire, alors qu’ils seront amplifiés en présence d’un fort anticyclone.

### 2.1.2 Artificialisation des sols

L’artificialisation des sols est une transformation irréversible d’un sol à caractère agricole, naturel ou forestier par des actions d’aménagement. Elle résulte principalement de l’urbanisation et de l’expansion des infrastructures, influencées par le développement démographique et économique. Les surfaces artificialisées regroupent diverses structures telles que l’habitat, les zones industrielles, les espaces verts associés, les réseaux de transport et les équipements de loisirs. L’artificialisation des sols entraîne leur imperméabilisation (Figure 2), ce qui entraîne des conséquences préjudiciables pour l’environnement, la production agricole et les écosystèmes. En effet, l’imperméabilisation des sols amplifie le ruissellement de l’eau plutôt que son infiltration, ce qui peut entraîner l’érosion des sols, des coulées d’eau boueuse et un risque accru d’inondation. Elle a également des effets négatifs sur la qualité chimique et écologique des eaux en favorisant le transfert de contaminants des sols vers les cours d’eau.




Figure 2: Illustration de l'artificialisation des sols (Vallée, 2025)

### 2.1.3 Albédo

L'albédo est une grandeur physique qui représente la proportion de lumière solaire réfléchiée par une surface (Figure 3). Cette valeur est importante pour le climat car elle mesure la quantité de rayonnement solaire renvoyée vers l'espace. L'albédo est une grandeur sans dimension, exprimée en pourcentage entre 0% et 100%, ou en chiffre entre 0 et 1, qui mesure la fraction de lumière réfléchiée par rapport à la quantité reçue.




Figure 3: Illustration du phénomène d'albédo (Vallée, 2025)

Par exemple, une surface parfaitement blanche a un albédo de 100%, car elle réfléchit toute la lumière solaire qu'elle reçoit. À l'inverse, une surface parfaitement noire a un albédo de 0%, car elle absorbe l'intégralité du rayonnement solaire qu'elle reçoit.

L'albédo des surfaces minérales, telles que les routes, les bâtiments et les trottoirs, est généralement faible, ce qui signifie qu'elles absorbent une grande quantité de rayonnement solaire et se réchauffent rapidement. En revanche, les zones végétalisées, telles que les parcs et les jardins, ont un albédo plus élevé et réfléchissent une plus grande quantité de rayonnement solaire, ce qui les maintient plus fraîches.

## 2.2 Définitions liées à l'intelligence artificielle (IA) et leur application aux UHI

### 2.2.1 Réseaux de neurones convolutifs et convolutions

On peut raisonnablement supposer que des facteurs comme l'albédo ou l'artificialisation des sols, qui influencent directement les phénomènes d'îlots de chaleur urbains, sont visibles et quantifiables à partir d'images satellites. Dès lors, le traitement d'images satellitaires constitue un outil prometteur pour mieux comprendre et modéliser ces phénomènes. Aujourd'hui, les réseaux de neurones convolutifs (CNN), une classe spécifique de réseaux de neurones profonds, représentent l'approche la plus performante pour analyser et extraire des informations significatives de ces images.

Un réseau neuronal convolutif (*Convolutional Neural Network*, CNN) est un type de réseau neuronal profond conçu pour traiter des données structurées en grille, telles que les images, en apprenant automatiquement des caractéristiques spatiales. Inspirés du système visuel humain, les CNNs sont largement utilisés dans des domaines comme la vision par ordinateur [3].




Figure 4: Architecture de base d'un réseau de neurones convolutionnel (CNN) et kernel (Cheung et al., 2020 [4]).

Au cœur de ces réseaux se trouve l'opération de convolution (Figure 4), qui consiste à appliquer un filtre, appelé noyau ou kernel, sur une image pour en extraire des caractéristiques spécifiques, comme des bords ou des textures pour les premières couches, et des filtres plus spécifiques à la tâche dans les dernières. Ce filtre, représenté par une petite matrice de poids, se déplace sur l'image, effectuant des multiplications avec les pixels voisins, puis additionne les résultats pour produire une nouvelle image appelée carte de caractéristiques (*feature map*). Les kernels sont optimisés lors de l'entraînement pour détecter des motifs pertinents dans les données. Cette opération permet au réseau de réduire la complexité des données tout en extrayant des motifs significatifs, ce qui rend l'apprentissage plus efficace.

Un *kernel* (ou noyau) est donc une petite matrice utilisée dans les réseaux de neurones convolutifs pour extraire des caractéristiques spécifiques d'une image, comme des bords, des textures ou des motifs. Les poids du kernel sont ajustés pendant l'entraînement grâce à des algorithmes comme la rétropropagation.

La rétropropagation (ou *backpropagation*) est un algorithme d'apprentissage supervisé qui ajuste les paramètres du modèle, les poids et les biais, pour réduire l'écart entre les prédictions et les valeurs réelles observées. Ce processus repose sur la descente du gradient, une méthode qui minimise une fonction de coût, généralement une fonction de perte, quantifiant l'écart entre les prédictions et les valeurs attendues. L'algorithme commence par une passée avant (*forward pass*) où le modèle fait une prédiction basée sur les poids initiaux. Ensuite, l'écart (ou erreur) entre la prédiction et la réalité est calculé. Durant la phase de rétropropagation, l'erreur est propagée en arrière à travers le réseau, couche par couche. Cela permet de calculer les dérivées partielles de l'erreur par rapport aux poids et aux biais de chaque neurone. Ces dérivées sont ensuite utilisées pour ajuster les paramètres via la descente du gradient, en modifiant les poids et les biais dans la direction qui minimise l'erreur. Ce processus est itératif et se répète à chaque epoch.

Une epoch correspond à un passage complet sur l'ensemble des données d'entraînement. Pendant une epoch, chaque donnée d'entraînement est utilisée pour ajuster les paramètres du modèle, afin d'améliorer ses prédictions. L'entraînement se déroule en plusieurs epochs pour permettre au modèle d'affiner progressivement ses paramètres. Plus le nombre d'epochs est élevé, plus le modèle peut perfectionner ses prédictions en affinant ses

paramètres à chaque itération. Cependant, lorsque le modèle est entraîné trop longtemps il devient trop spécifique aux données d'entraînement, il peut mémoriser les exemples au lieu de comprendre les tendances générales. Ce phénomène, appelé surapprentissage (ou *overfitting*), nuit à la capacité du modèle à généraliser sur des données nouvelles. En d'autres termes, le surapprentissage se produit lorsque le modèle perd sa capacité à extraire des caractéristiques généralisables, car il se concentre excessivement sur les détails et les bruits spécifiques des données d'entraînement.

## 2.3 Méthodes empiriques de mesure

Les méthodes empiriques de mesure sont couramment utilisées pour collecter des données sur les îlots de chaleur urbains (UHI), fournissant des informations sur les températures de surface et leur distribution dans l'espace urbain. Parmi les approches les plus courantes, on trouve l'utilisation de capteurs de température sur des plateformes mobiles ou fixes. Une étude de Liu et al. (2017) [5] illustre cette méthode en utilisant des capteurs montés sur des vélos, couplés à un GPS, afin de mesurer la température en temps réel lors de trajets urbains. Cette méthode permet de cartographier la variation spatiale des températures à différentes échelles et de collecter des données continues.

Cependant, cette approche présente plusieurs limites : la couverture spatiale reste restreinte car les capteurs mesurent principalement sur des voies, négligeant les zones comme les espaces verts ou les quartiers résidentiels moins accessibles. De plus, la non-reproductibilité des trajets effectués par les véhicules ou vélos rend les résultats difficiles à répéter. Enfin, les relevés étant principalement réalisés en journée, les mesures nocturnes, où l'UHI est souvent plus marqué, sont souvent ignorées.

Une autre méthode empirique repose sur l'utilisation de capteurs infrarouges [6], souvent installés sur des télescopes ou des satellites, pour mesurer directement la température de surface en détectant le rayonnement infrarouge émis par la Terre. Cette technique est utile pour mesurer les variations de température sur de larges zones urbaines et sur des surfaces imperméabilisées, telles que les routes et bâtiments. Les capteurs infrarouges permettent ainsi de cartographier les UHI à une échelle beaucoup plus large que les capteurs mobiles. Cependant, bien que les capteurs infrarouges soient efficaces à grande échelle, ils présentent des limites. Ils sont sensibles aux conditions météorologiques, telles que la présence

de nuages ou l'humidité, ce qui peut affecter la précision des résultats. En outre, ces capteurs ne mesurent que la température des surfaces visibles, sans fournir d'informations sur la température de l'air ou la chaleur emmagasinée dans les couches profondes de l'environnement urbain.

Ainsi, bien que les méthodes empiriques comme les capteurs mobiles et infrarouges soient précieuses pour mesurer les UHI, elles comportent des limites qui peuvent affecter leur précision et reproductibilité.

## 2.4 Méthodes basées sur l'IA

L'application des techniques d'Intelligence Artificielle, en particulier du *deep learning*, à l'étude des phénomènes climatiques urbains, comme la température de surface et les UHI, a connu des avancées récentes importantes. Le *deep learning*, grâce aux CNN, permet de surmonter certaines limites des modèles classiques, notamment en termes de précision et de capture des dynamiques complexes.

Une étude [7] a montré que le *deep learning* permet une meilleure prédiction de la température de surface et des températures de l'air par rapport aux méthodes traditionnelles. Un modèle combinant des variables atmosphériques et radiatives a permis de réduire les erreurs de prévision, avec des biais et des erreurs remarquablement faibles, notamment pour la température de surface en milieu urbain. L'intégration de variables radiatives, telles que les flux de chaleur sensible et latente, a été cruciale pour améliorer les performances du modèle.

Ces travaux montrent qu'un ensemble de prédicteurs combinant variables atmosphériques et radiatives améliore la précision des prédictions, notamment pour les îlots de chaleur urbains, diurnes et nocturnes. Cette approche a réduit les biais saisonniers et optimisé la gestion des extrêmes thermiques, surtout en période chaude. Les modèles *deep learning*, et plus particulièrement les CNN, ont montré leur capacité à traiter des données complexes et à généraliser efficacement les résultats à l'échelle urbaine.

## 3 Méthode

### 3.1 Création du jeu de données

La collecte de données est une étape essentielle dans la création d'un modèle d'IA. En effet, le nombre d'échantillons d'entraînement influence directement la qualité des résultats finaux. Dans notre cas, nous avons trouvé nos données sur le site « *UHI Web Maps* », un outil en libre-service proposant des cartes interactives basées sur des données thermiques infrarouges captées par des satellites comme *Landsat*. Ces données permettent de mesurer directement la chaleur émise par les surfaces terrestres et de visualiser les variations de température.

Le site propose un accès libre à sept cartes interactives représentant différentes villes : Toronto, Melbourne, Singapour, Lyon, North Andover, Los Angeles et Santiago. Pour créer notre modèle, nous avons besoin d'images fixes des cartes thermiques et de leurs images satellites correspondantes.

Afin de répondre à ce besoin, nous avons développé un algorithme capable de réaliser des captures d'écran (Figure 5). Grâce à cet outil, nous avons pu les capturer par lots de 10 images de 300x300 pixels.




Figure 5: Illustration du programme développé pour capturer les 4370 images (Vallée, 2025)

Cette opération nous a permis de constituer un ensemble de 4 370 cartes de chaleur, chacune associée à son image satellite.

## 3.2 Prétraitement des données

Une fois notre jeu de données collecté, il est nécessaire de le préparer. L'étape de prétraitement regroupe les opérations effectuées sur les données brutes avant leur utilisation dans le modèle d'apprentissage. L'objectif est de rendre les données exploitables et adaptées aux besoins de l'algorithme.

Dans notre cas, nous avons converti toutes les cartes de chaleur en nuances de gris (Figure 6, Figure 7). Un pixel codé en RVB (rouge, vert, bleu) est représenté sur 3 dimensions, ce qui le rend trois fois plus lourd qu'un pixel en nuances de gris, codé sur une seule dimension. En réduisant la taille des images, nous diminuons ainsi l'effort de calcul et le temps d'exécution de notre modèle. Cette conversion ne modifie pas les informations contenues dans nos images, car les éléments essentiels sont les différentes zones colorées, indiquant des variations de température.

Pour cette conversion, nous avons associé les températures les plus élevées, représentées par le rouge, à la teinte la plus claire du nuancier de gris, le blanc. À l'inverse, les températures les plus basses, représentées par le bleu, ont été associées à la teinte la plus sombre, le noir. Un dégradé a ensuite été généré entre ces deux extrêmes pour préserver les nuances cruciales présentes dans nos données.

Ainsi, nous avons obtenu des cartes de chaleur en nuances de gris, dont le poids est réduit tout en conservant l'information essentielle pour l'analyse.

Pour réduire la taille des images et diminuer l'effort de calcul, nous avons normalisé chaque pixel en le divisant par 255, une étape fondamentale en *deep learning* pour les données d'entrée. Cette normalisation transforme les valeurs des pixels, initialement comprises entre 0 et 255, en des valeurs entre 0 et 1, tout en conservant les différences relatives entre les zones de l'image. Nous avons également recadré les images à une taille uniforme de 320x320 pixels. Cette dimension garantit l'homogénéité des données et facilite le traitement dans le réseau.




Figure 6: Carte de chaleur




Figure 7: Carte de chaleur en nuance de gris

### 3.3 Séparation des données

Une fois les données préparées, il faut les charger dans notre algorithme. Il est crucial de diviser les données en trois ensembles distincts : entraînement, validation et test.




Figure 8: Schéma des phases du modèle et fonctionnement de l'entraînement d'un modèle d'intelligence artificielle (Vallée, 2025)

### 3.3.1 Entraînement

Le modèle est d'abord alimenté avec le jeu de données d'entraînement, qui lui permet d'ajuster ses paramètres internes (poids et biais dans les réseaux de neurones) à travers un processus d'optimisation. Il calcule les erreurs entre ses prédictions et les résultats attendus, puis corrige ses erreurs en ajustant les paramètres. L'entraînement se déroule sur plusieurs epochs, cela signifie que le modèle passe plusieurs fois sur les données pour améliorer progressivement sa capacité à faire des prédictions correctes (Figure 8).

### 3.3.2 Validation

Un deuxième jeu de données, appelé jeu de validation, est utilisé pendant l'entraînement pour mesurer l'évolution de la performance du modèle. Lors de chaque epochs, l'erreur est calculée, mais le modèle n'est pas autorisé à rétropropager cette erreur, c'est-à-dire à ajuster les poids et les biais. Cette procédure permet d'évaluer si le modèle est capable de généraliser sur des données inconnues. Les résultats obtenus sur le jeu de validation fournissent une indication de la capacité du modèle à faire de bonnes prédictions sur de nouvelles données. La validation joue ainsi un rôle de contrôle, veillant à ce que le modèle ne se limite pas à mémoriser les données d'entraînement, un phénomène connu sous le nom de « sur-apprentissage » ou *overfitting* (Figure 8).

### 3.3.3 Test

La phase de test intervient une seule fois lorsque l'entraînement et la validation sont terminés. Elle évalue la performance finale du modèle de manière indépendante. Un troisième jeu de données, appelé jeu de test, est utilisé. Ces données n'ont jamais été vues par le modèle, ni pendant l'entraînement ni pendant la validation. L'objectif est d'évaluer la capacité du modèle à faire des prédictions sur de nouvelles données. (Figure 8)

Dans notre modèle, nous avons fixé le nombre d'epochs à 100, ce qui signifie que pour le test, parmi les 100 epochs effectuées, le modèle charge les paramètres du réseau correspondant à l'epoch où il a fait le moins d'erreur moyenne sur le jeu de validation. Cela garantit que le modèle testé est celui qui a la meilleure capacité de généralisation.

### 3.3.4 Répartition des données

On répartit les données de la manière suivante (Figure 9) : 70% pour l'entraînement, 15% pour la validation, et 15% pour le test.

|                                  | ENTRAINEMENT | VALIDATION | TEST |       |
|----------------------------------|--------------|------------|------|-------|
| Pourcentage du jeu de donnée (%) | 70           | 15         | 15   | Total |
| Nombre d'images                  | 3059         | 656        | 656  | 4370  |

Figure 9: Tableau de répartition des données selon la phase (Vallée, 2025)

Pour diversifier le jeu de données et garantir que chaque époque d'entraînement utilise des données légèrement différentes, nous appliquons des variations aléatoires, telles que des symétries et des rotations aux images. Ces transformations n'altèrent ni la nature ni l'information contenue dans les images, tout en permettant de multiplier artificiellement la taille du jeu de données, une technique connue sous le nom d'augmentation de données. Bien que le modèle puisse revoir certaines images d'origine, cela n'est pas problématique, car l'objectif est avant tout d'enrichir la diversité des données disponibles pour l'apprentissage. En revanche, ces variations aléatoires ne sont pas appliquées au jeu de validation ni au jeu de test, afin que les performances soient évaluées dans des conditions réelles, sans biais lié aux transformations.

## 3.4 Architecture du réseau

L'architecture de notre modèle repose sur une combinaison d'un encodeur basé sur MobileNetV2 et d'un décodeur que nous avons conçu nous-mêmes (Figure 10). Les architectures encodeur / décodeur sont utilisées pour traiter et transformer les données [8]. Une architecture encodeur/décodeur est un modèle d'apprentissage automatique conçu pour transformer des données d'un format à un autre en deux étapes complémentaires. L'encodeur analyse et compresse les informations d'entrée, comme une image, en une représentation compacte, appelée vecteur latent, qui capture les caractéristiques essentielles tout en réduisant la complexité des données. Cette phase permet de filtrer les détails superflus tout en conservant les informations clés nécessaires à la tâche ciblée. Le décodeur,

quant à lui, utilise cette représentation compacte pour reconstruire les données dans un format interprétable.




Figure 10: Architecture simplifiée de notre modèle (Vallée, 2025)

L'entrée du modèle, appelée image d'entrée, correspond à une image satellite. Cette image est d'abord traitée par l'encodeur, où nous avons utilisé *MobileNetV2*, un modèle développé par Google en 2018 [9], réputé pour sa légèreté et son efficacité, particulièrement adapté aux appareils mobiles. *MobileNetV2* repose sur une technique de blocs résiduels inversés, où les données passent par une étape d'agrandissement des dimensions suivie d'une réduction. Cette approche permet de conserver les informations essentielles tout en limitant le nombre de paramètres. L'encodeur est ainsi constitué de blocs de convolutions, combinés à des fonctions d'activation ReLU et à des couches de *pooling*, afin d'extraire les caractéristiques importantes de l'image d'entrée. Nous avons choisi ce modèle, car il ne part pas de zéro : il peut tirer parti des connaissances préalablement acquises grâce à son pré-entraînement sur des bases de données générales.

Le décodeur, que nous avons conçu nous-mêmes pour répondre aux besoins spécifiques de notre projet, reconstruit une image appelée Image Reconstituée. Contrairement à l'encodeur, qui compresse les données en une représentation compacte, le décodeur utilise une série de 11 couches, comprenant des étapes d'*upsampling* (agrandissement progressif des dimensions de l'image) entre les convolutions, afin de retrouver la taille initiale de l'image en sortie. Cette reconstruction vise à produire une carte de chaleur représentant les zones d'intérêt identifiées dans l'Image d'entrée. L'Image Reconstituée est ensuite comparée à une Image Objectif, qui représente la réalité attendue, afin d'évaluer la qualité des prédictions et d'ajuster l'apprentissage en conséquence.

## 3.5 Pré-entraînement

Nous avons débuté par une étape de pré-entraînement, au cours de laquelle le modèle a été formé à reconstruire l'image d'entrée. L'objectif était de lui permettre de "comprendre" les images satellites et d'identifier les éléments principaux qui les composent. Pour ce faire, nous avons fourni les images satellites en entrée, afin que le modèle apprenne à les reconstruire à l'identique, sans se focaliser sur des détails spécifiques, mais plutôt sur les structures et caractéristiques globales. Ainsi, lors de l'entraînement pour l'objectif final, le modèle ne partira pas de zéro, ayant déjà acquis une compréhension des données importantes constituant l'image satellite.

Pour nous assurer que l'image soit reconstruite fidèlement pendant cette étape, nous avons mesuré la différence entre l'image d'entrée et l'image générée par le modèle à l'aide de l'erreur quadratique moyenne (MSE).

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Où :

- $y_i$  est la valeur réelle du pixel  $i$  de l'image d'entrée (0 ou 1),
- $\hat{y}_i$  est la valeur prédite pour le pixel  $i$ ,
- $n$  est le nombre de pixels par image.

La MSE calcule la moyenne des carrés des différences entre les valeurs réelles des pixels de l'image d'entrée  $y_i$  et les valeurs prédites  $\hat{y}_i$ . Concrètement, pour chaque pixel  $i$ , on calcule la différence entre sa valeur réelle  $y_i$  et la valeur prédite  $\hat{y}_i$ , puis on élève cette différence au carré. Cette opération permet de pénaliser davantage les erreurs importantes, car les grandes différences sont amplifiées, tout en supprimant les signes négatifs. Ensuite, on calcule la moyenne de ces erreurs carrées sur tous les pixels de l'image pour obtenir une mesure globale de la précision de la reconstruction. L'objectif est de guider l'apprentissage du modèle afin qu'il minimise cette erreur. Une faible MSE signifie que l'image générée est très proche de l'image d'origine, indiquant que le modèle a bien appris les caractéristiques essentielles des images.

## 3.6 Entraînement

Nous pouvons donc passer à l'étape suivante, l'entraînement. À ce stade, nous fournissons en entrée l'image satellite que nous demandons à notre modèle de reconstruire. Cette fois-ci, nous effectuons une minimisation de l'erreur en comparant l'image prédite à la carte de chaleur associée (en nuances de gris). Notre objectif est que, à partir d'une image satellite, le modèle produise la carte de température correspondante, nous permettant ainsi d'observer les UHI.

L'erreur du modèle est calculée en combinant deux fonctions de perte. La *Binary Cross Entropy* (BCE) et la *Dice Loss* [10]

La BCE mesure la différence entre les probabilités prédites pour chaque pixel par le modèle ( $\hat{y}_i$ ) et les valeurs réelles des pixels ( $y_i$ ), en attribuant une pénalité plus forte aux prédictions incorrectes. La BCE pour une image est définie comme ceci :

$$\text{BCE} = -\frac{1}{n} \sum_{i=1}^n [y_i \cdot \log(\hat{y}_i) + (1 - y_i) \cdot \log(1 - \hat{y}_i)]$$

Où :

- $y_i$  est la valeur réelle associée au pixel  $i$ , qui peut prendre les valeurs 0 ou 1,
- $\hat{y}_i$  est la probabilité prédite par le modèle pour le pixel  $i$ ,
- $n$  est le nombre total de pixels considérés dans l'image.

La fonction calcule la différence entre  $y_i$  et  $\hat{y}_i$  pour chaque pixel de l'image. Pour chaque pixel  $i$ , si la valeur réelle ( $y_i$ ) est proche de la probabilité prédite ( $\hat{y}_i$ ), la BCE associée sera faible. En revanche, une prédiction incorrecte, où  $\hat{y}_i$  s'éloigne fortement de  $y_i$ , sera fortement pénalisée en raison de l'utilisation des logarithmes. La somme des erreurs calculées pour tous les pixels est ensuite divisée par  $n$ , le nombre total de pixels, pour obtenir une mesure moyenne de la perte sur l'image ou l'ensemble de données.

La *Dice loss* [10], quant à elle, est une fonction de perte utilisée pour évaluer le chevauchement entre les zones prédites par le modèle ( $p_i$ ) et les zones réelles ( $g_i$ ). Cette

métrique est particulièrement efficace pour les tâches de segmentation d'images où il est essentiel de détecter avec précision les formes, les tailles et l'étendue des régions d'intérêt. Contrairement à des fonctions de perte strictement basées sur des différences point par point, la Dice loss considère la similarité globale entre deux ensembles.

Elle est définie par l'expression suivante :

$$\text{Dice Loss} = 1 - \frac{2 \cdot \sum_{i=1}^n (p_i \cdot g_i) + \epsilon}{\sum_{i=1}^n p_i + \sum_{i=1}^n g_i + \epsilon}$$

Où :

- $p_i$  est la probabilité prédite par le modèle pour le pixel  $i$ , indiquant la probabilité que ce pixel appartienne à la classe d'intérêt,
- $g_i$  est la valeur réelle pour le pixel  $i$ , qui peut être 0 ou 1,
- $\epsilon$  est une petite constante ajoutée pour éviter une division par zéro
- $n$  est le nombre total de pixels dans l'image.

La *Dice loss* mesure la similitude entre les zones prédites ( $p_i$ ) et les zones réelles ( $g_i$ ) en comparant leur intersection ( $p_i \cdot g_i$ ) à leur union ( $\sum_{i=1}^n p_i + \sum_{i=1}^n g_i$ ). Une *Dice loss* faible signifie que les prédictions et les zones réelles se chevauchent fortement, montrant que le modèle identifie bien les zones d'intérêt. Le facteur  $n$ , correspondant au nombre total de pixels, garantit que la *Dice loss* reste cohérente quelle que soit la taille des images.

En combinant ces deux fonctions, le modèle peut être à la fois précis localement et capturer efficacement la structure globale des zones d'intérêt sur les cartes de chaleur [10]. Après plusieurs tests aléatoires, nous avons déterminé un ratio optimal pour cette combinaison : 36 % pour la BCE et 64 % pour la *Dice loss* :

$$\text{Erreur Totale} = 0.36 \cdot \text{BCE} + 0.64 \cdot \text{DiceLoss}$$

## 4 Résultats

### 4.1 Explication des résultats et description

#### Analyse des courbes de perte




Figure 11: Courbe de perte de l'entraînement (Vallée, 2025)




Figure 12: Courbe de perte de la validation (Vallée, 2025)

La Figure 11 illustre l'évolution de l'erreur (loss) en fonction des epochs lors de la phase d'entraînement. On observe une légère décroissance de la courbe, indiquant que le modèle améliore progressivement ses performances au fil des itérations. Bien que cette diminution ne soit pas très prononcée, elle reflète une réduction de l'erreur sur les données d'entraînement.

La Figure 12 présente la courbe de perte en phase de validation. Celle-ci montre également une décroissance globale, bien qu'elle soit plus irrégulière, avec des oscillations. Malgré ces fluctuations, la tendance générale reste à la baisse, ce qui traduit une amélioration de la capacité du modèle à généraliser sur les images de validation. Par ailleurs, il est important de noter que l'échelle des abscisses diffère entre les phases d'entraînement et de validation, ce qui peut influencer l'interprétation des variations.

Les courbes issues de la phase de pré-entraînement sont disponibles en annexe.

## Analyse des images obtenues










|         | Image A :                                                                           | Image B :                                                                           | Image C :                                                                           | Image D :                                                                           | Image E :                                                                            | Similarité (%) | Annotations                                                                   |
|---------|-------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------|----------------|-------------------------------------------------------------------------------|
|         | Image satellite                                                                     | Données empiriques                                                                  | Image en nuances de gris                                                            | Image prédite                                                                       | Image prédite recolorisée                                                            |                |                                                                               |
| n° 518  |    |    |    |    |    | 79.9           | Melbourne (AUS)<br>Zone rurale<br>(Forêt, plaine)<br>Similarité : Bonne       |
| n° 687  |    |    |    |    |    | 64.6           | Melbourne (AUS)<br>Zone mixte<br>(Forêt, plaine, ville)<br>Similarité : Bonne |
| n° 777  |    |    |    |    |    | 76.1           | Singapour<br>Zone mixte<br>(Forêt, ville)<br>Similarité : Bonne               |
| n° 787  |    |    |    |    |    | 47.3           | Singapour<br>Zone urbaine<br>(ville dense)<br>Similarité : Mauvaise           |
| n° 1405 |   |   |   |   |   | 76.6           | Santiago (CHIL)<br>Zone rurale<br>(Forêt, plaine)<br>Similarité : Bonne       |
| n° 1722 |  |  |  |  |  | 25.1           | Santiago (CHIL)<br>Zone rurale<br>(plaine)<br>Similarité : Bonne              |
| n° 1857 |  |  |  |  |  | 80.1           | North Andover (US)<br>Zone urbaine<br>(ville)<br>Similarité : Bonne           |
| n° 2470 |  |  |  |  |  | 49.4           | Toronto (CAN)<br>Zone rurale<br>(champs)<br>Similarité : Mauvaise             |
| n° 2708 |  |  |  |  |  | 19.2           | Toronto (CAN)<br>Zone rurale<br>(Forêt)<br>Similarité : Mauvaise              |
| n° 2854 |  |  |  |  |  | 67.8           | Toronto (CAN)<br>Zone mixte<br>(Forêt, ville)<br>Similarité : Bonne           |
| n° 3683 |  |  |  |  |  | 82.8           | Los Angeles (US)<br>Zone urbaine<br>(ville)<br>Similarité : Bonne             |
| n° 4199 |  |  |  |  |  | 75.5           | Los Angeles (US)<br>Zone urbaine<br>(ville)<br>Similarité : Bonne             |
| n° 4368 |  |  |  |  |  | 84.2           | Los Angeles (US)<br>Zone urbaine<br>(ville)<br>Similarité : Bonne             |

Figure 13: Résultats de résultat de la prédiction des UHI : Comparaison des images et similarité (Vallée, 2025)

Les résultats présentés Figure 13 proviennent de la phase de test, au cours de laquelle l'IA génère des prédictions sur des données qu'elle n'a jamais vues auparavant. Pour mesurer la qualité des prédictions générées par l'IA, nous avons utilisé la SSIM (*Structural Similarity Index Measure*). Cet indicateur, largement utilisé dans l'analyse d'images, compare l'image prédite  $D$  avec l'image provenant des données empiriques  $C$  (Figure 13), en se basant non seulement sur les différences de luminance et de contraste, mais aussi sur la structure des motifs présents dans les deux images. Contrairement à des métriques classiques, la SSIM est conçue pour évaluer la similitude perçue par un humain. Elle attribue une valeur entre -1 et 1, où 1 correspond à une correspondance parfaite entre les deux images.

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}$$

Où :

- $\mu_x$  et  $\mu_y$  représentent les moyennes des intensités des pixels des images  $x$  et  $y$ ,
- $\sigma_x^2$  et  $\sigma_y^2$  sont les variances des pixels des images  $x$  et  $y$ ,
- $\sigma_{xy}$  est la covariance entre les pixels des deux images  $x$  et  $y$ ,
- $C_1$  et  $C_2$  sont des constantes qui empêchent la division par zéro, définies comme :

$$C_1 = (K_1L)^2 \quad \text{et} \quad C_2 = (K_2L)^2,$$

où  $K_1$  et  $K_2$  sont des coefficients constants (typiquement petits, comme 0.01 et 0.03), et  $L$  est l'intensité maximale possible des pixels (par exemple, 255 pour des images en 8 bits).

Cette formule est calculée localement, pixel par pixel, pour comparer les deux images  $x$  et  $y$  (ici,  $D$  et  $C$ ) (Figure 13). Elle permet ainsi d'obtenir une mesure globale de la similarité de structure entre ces images. Une valeur élevée de SSIM indique que l'image prédite  $D$  correspond fidèlement à la structure de l'image de référence  $C$  (Figure 13).

Les résultats obtenus sont globalement satisfaisant, avec une moyenne de similarité SSIM de 74,3 % sur les 656 images de test. Ces résultats montrent que le modèle est capable de produire des images dont la structure est bien préservée par rapport aux images

de référence. De plus, lorsque l'on examine les valeurs de similarité par ville (Figure 14), on constate que plusieurs d'entre elles affichent des performances notables.

| Villes              | SSIM (%) | Nombre d'images |
|---------------------|----------|-----------------|
| North Andovers (US) | 84,4     | 32              |
| Los Angeles (US)    | 77,9     | 122             |
| Lyon (FR)           | 76,3     | 43              |
| Toronto (CAN)       | 72       | 241             |
| Melbourne (CAN)     | 71,3     | 112             |
| Singapore           | 69,7     | 30              |
| Santiago (CHIL)     | 68,8     | 76              |
| Total               | 74,3     | 656             |

Figure 14: Tableau du taux de similarité calculé par ville (Vallée, 2025)

Par exemple, North Andovers obtient une similarité de 84,4 %, ce qui montre une très bonne adéquation entre les images de référence et les images générées par le modèle. Lyon et Los Angeles suivent avec des taux respectivement de 76,3 % et 77,9 % indiquant une excellente capacité du modèle à reproduire la structure des images dans ces environnements urbains.

Toronto, Melbourne et Singapore affichent des taux légèrement plus bas (72 %, 71,3 % et 69,7 %), tandis que Santiago présente la valeur la plus faible à 68,8 %. Néanmoins, ces résultats restent globalement satisfaisants et témoignent de la robustesse du modèle à s'adapter à des environnements urbains divers, tout en mettant en lumière les défis rencontrés dans des zones plus homogènes.

En effet, certains taux de similarité apparaissent plus faibles pour certains résultats. Par exemple Figure 13, pour le n°2854, le pourcentage de similarité est relativement bas à 67 %. Pourtant, lorsque l'on compare visuellement les images C et D, la différence ne semble pas si marquée. On peut toutefois remarquer sur l'image C la présence de taches noires qui figurent également sur l'image B. Ces taches noires correspondent à des défauts dans les données, représentant des zones sans information, rendues noires. Ces zones, fortement contrastées avec leur environnement, faussent les résultats lors du calcul de la similarité.

On observe également des taux de similarité faibles pour d'autres cas : 787 (47,3 %), 1722 (25,1 %), 2470 (49,4 %) et 2708 (19,2 %). Une tendance commune peut être identifiée : en examinant l'image satellite (image A) de chaque lot, on remarque que ces zones correspondent toutes à des paysages très homogènes. Par exemple, pour le 787, il s'agit d'une ville très dense sur l'ensemble de l'image. Pour le 1722, on observe principalement une plaine de montagne. Le 2470 représente une zone agricole avec des champs, tandis que le 2708 montre une forêt dense.

Ces faibles performances sont compréhensibles, car lorsque les images présentent peu de contraste, c'est-à-dire qu'elles manquent de variations marquées entre les éléments du paysage, le modèle a du mal à identifier les différences subtiles qui pourraient indiquer des sources de chaleur ou de fraîcheur. Dans des environnements homogènes, les caractéristiques extraites par le modèle deviennent moins discriminantes, rendant plus difficile la distinction entre des zones potentiellement plus chaudes ou plus fraîches. Par exemple, dans une forêt dense ou une étendue de champs, les variations de température ne sont pas toujours perceptibles visuellement ou thermiquement de manière évidente. Ce manque de diversité dans les données d'entrée limite donc la capacité du modèle à généraliser ou à produire des cartes précises dans ces cas spécifiques.

De cela nous pouvons conclure que notre modèle, bien que perfectible est un moyen efficace d'identifier les îlots de chaleur urbains. Il offre des avantages significatifs par rapport aux mesures empiriques qui restent peu adaptables.

## Mise en application de notre programme

Nous avons donc développé un programme informatique capable de générer une carte de chaleur à partir d'une image satellite. Ce programme a été testé avec succès sur la ville de Tours. En intégrant les images satellites de Tours (Figure 15), nous avons obtenu les cartes de chaleur correspondantes (Figure 16). Nous les avons superposées aux images satellite, pour avoir une meilleure visualisation des îlots de chaleur urbains, facilitant ainsi leur identification et leur analyse.



Figure 15: Image satellite de Tours en entrée du programme (Vallée, 2025)



Figure 16: Carte de chaleur superposée à l'image satellite de Tours, générée par notre modèle (Vallée, 2025)

À partir des cartes de chaleur obtenues pour la ville de Tours, plusieurs observations peuvent être faites. Les zones très denses, comme le centre-ville, apparaissent comme des zones particulièrement chaudes. Cependant, la présence de la Loire joue un rôle essentiel en créant un îlot de fraîcheur bénéfique au bien-être des habitants. De plus, des espaces verts comme le parc du Vinci et le jardin du Musée des Beaux-Arts contribuent à une zone plus fraîche à l'ouest du centre de Tours, offrant ainsi des refuges thermiques locaux. Cependant, nous pouvons repérer quelques critiques à faire à notre modèle. On voit notamment des discontinuités entre les images générées, ce qui indique un manque de cohérence spatiale dans les prédictions. Ces irrégularités soulignent la nécessité d'améliorer le modèle.

## 4.2 Les pistes d'amélioration

Pour améliorer la performance et la robustesse de notre modèle, plusieurs pistes peuvent être envisagées. Tout d'abord, l'augmentation de la diversité et de la quantité des données pourrait considérablement améliorer la capacité de généralisation du modèle. Cela inclut l'intégration de données provenant de différentes régions du monde, telles que l'hémisphère Nord et Sud, des zones rurales et urbaines, ainsi que des petites villes et grandes métropoles. De plus, il serait pertinent de prendre en compte des périodes variées, incluant l'été et l'hiver, le jour et la nuit, ou encore différentes conditions météorologiques, par le temps ensoleillé ou nuageux. Une telle diversité permettrait au modèle de mieux s'adapter à des conditions climatiques et environnementales variées.

Ensuite, il serait intéressant d'intégrer des données de température de l'air, en complément des températures de surface fournies par les données satellitaires. Les températures de l'air sont particulièrement pertinentes pour l'étude des îlots de chaleur urbains (UHI) car elles permettent une meilleure évaluation de l'impact sur le confort thermique des populations. Contrairement aux températures de surface, qui reflètent la chaleur émise par les matériaux visibles, les températures de l'air prennent en compte les interactions thermiques à hauteur humaine, ce qui les rend plus représentatives du ressenti réel des habitants. En incluant ces données, il serait possible d'améliorer la précision des analyses et de développer des stratégies d'adaptation mieux adaptées au bien-être des populations urbaines.

Une piste d'amélioration pourrait être l'adoption d'une approche multi-échelle. Notre analyse repose sur une seule échelle spatiale, limitant ainsi la portée des résultats. En combinant des analyses détaillées pour des zones spécifiques avec des évaluations globales à l'échelle des grandes régions urbaines, il serait possible d'obtenir une vision plus complète, nuancée et utiles des dynamiques des îlots de chaleur.

## 5 Conclusion

Ce travail a permis de concevoir et de tester un modèle d'intelligence artificielle basé sur une architecture encodeur-décodeur, capable de générer des cartes de chaleur à partir d'images satellites, contribuant à une meilleure identification des îlots de chaleur urbains (UHI). Les résultats obtenus montrent que le modèle développé est globalement performant pour identifier les zones de chaleur et de fraîcheur dans des environnements urbains variés. Par exemple, l'analyse appliquée à la ville de Tours met en évidence des observations pertinentes, telles que l'effet rafraîchissant de la Loire et des espaces verts, qui soulignent l'importance des infrastructures naturelles dans la régulation thermique des villes.

Cependant, des limites ont été identifiées, notamment des discontinuités spatiales dans les prédictions et des performances inégales dans des environnements homogènes ou peu contrastés. Ces résultats témoignent des défis liés à la modélisation des UHI, en particulier dans des contextes où les données disponibles manquent de diversité ou de précision.

Malgré ces limites, ce modèle constitue une base prometteuse pour des études plus approfondies sur les UHI. En intégrant des pistes d'amélioration, telles que l'enrichissement des données par des observations multisaisonnières ou multiscalaires, ou encore l'ajout de données sur les températures de l'air, il serait possible d'affiner les résultats et d'étendre les capacités d'analyse. À terme, ces améliorations pourraient offrir des outils précieux pour soutenir la planification urbaine et développer des stratégies d'adaptation aux défis climatiques.

En conclusion, ce projet met en lumière le potentiel des outils d'intelligence artificielle et des données satellitaires pour aborder des problématiques environnementales complexes, tout en ouvrant la voie à des avancées futures dans la modélisation et l'analyse des îlots de chaleur urbains.

## References

- [1] Gardes, T., Schoetter, R., Hidalgo, J., Long, N., Marquès, E., & Masson, V. (2020). Statistical prediction of the nocturnal urban heat island intensity based on urban morphology and geographical factors - An investigation based on numerical model results for a large ensemble of French cities. *Science of The Total Environment*, 737, 139253. Disponible sur : <https://linkinghub.elsevier.com/retrieve/pii/S0048969720327704> (consulté en mai 2023).
- [2] Howard, L. (1818). *The Climate of London: Deduced from Meteorological Observations, Made at Different Places in the Neighbourhood of the Metropolis*. W. Phillips, George Yard, Lombard Street. Disponible sur : <https://books.google.fr/books?id=7skTAAAYAAJ> (consulté en mai 2023).
- [3] Barillaro, L. (2024). Artificial Neural Networks: CNN. In *Reference Module in Life Sciences*. Elsevier. Disponible sur : <https://www.sciencedirect.com/science/article/pii/B9780323955027000993> (consulté en décembre 2024).
- [4] Cheung, M., Shi, J., Wright, O., Liu, X., Jiang, L., & Moura, J. (2020). Graph Signal Processing and Deep Learning: Convolution, Pooling, and Topology. *arXiv*. Disponible sur : <https://doi.org/10.48550/arXiv.2008.01247> (consulté en janvier 2025).
- [5] Liu, L., Lin, Y., Liu, J., Wang, L., Wang, D., Shui, T., Chen, X., & Wu, Q. (2017). Analysis of local-scale urban heat island characteristics using an integrated method of mobile measurement and GIS-based spatial interpolation. *Building and Environment*, 117, 191–207. Disponible sur : <https://linkinghub.elsevier.com/retrieve/pii/S0360132317301117> (consulté en mai 2023).
- [6] Arrau, C.P., & Pena, M.A. (2016). Urban Heat Islands (UHIs). [WWW Document]. Disponible sur : <https://www.urbanheatislands.com/uhi-web-maps> (consulté en novembre 2024).
- [7] Johannsen, F., Soares, P. M. M., & Langendijk, G. S. (2024). On the deep learning approach for improving the representation of urban climate: The Paris urban heat island and temperature extremes. *Urban Climate*, 56, 102039. Disponible sur : <https://www.sciencedirect.com/science/article/pii/S1568169724000391> (consulté en janvier 2025).

[//www.sciencedirect.com/science/article/pii/S2212095524002359](http://www.sciencedirect.com/science/article/pii/S2212095524002359) (consulté en janvier 2025).

- [8] Badrinarayanan, V., Kendall, A., & Cipolla, R. (2016). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *arXiv*. Disponible sur : <http://arxiv.org/abs/1511.00561> (consulté en novembre 2024).
- [9] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. In *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 4510–4520). Salt Lake City, UT: IEEE. Disponible sur : <https://ieeexplore.ieee.org/document/8578572/> (consulté en novembre 2024).
- [10] Taghanaki, S. A., Zheng, Y., Zhou, S. K., Georgescu, B., Sharma, P., Xu, D., Comaniciu, D., & Hamarneh, G. (2019). Combo loss: Handling input and output imbalance in multi-organ segmentation. *Computerized Medical Imaging and Graphics*, 75, 24–33. Disponible sur : <https://linkinghub.elsevier.com/retrieve/pii/S0895611118305688> (consulté en décembre 2024).

## A Données complémentaires




Figure 17: Courbe de perte durant le pré-entraînement (Vallée, 2025)




Figure 18: Courbe de perte de la validation du pré-entraînement (Vallée, 2025)

**Directeur de recherche :**

Mindjid MAIZIA

**Gabrielle VALLEE**

**PRI/DAE 5**

**UIT/RESEAU**

**2024/2025**

## **Prédiction des Ilots de Chaleur Urbains : Utilisation de l'intelligence artificielle pour la modélisation des zones à forte température**

**Résumé :** Les Ilots de Chaleur Urbains (UHI) constituent un enjeu environnemental et sociétal majeur, influençant le confort thermique et la qualité de vie en milieu urbain. Cette étude explore l'utilisation de l'intelligence artificielle, pour modéliser et cartographier les UHI à partir d'images satellites. Nous proposons un modèle basé sur une architecture encodeur-décodeur, utilisant MobileNetV2 comme encodeur, optimisé pour extraire les caractéristiques essentielles des images satellitaires et produire des cartes thermiques (*heat maps*) détaillées. Les résultats montrent que le modèle est capable de généraliser efficacement sur des données provenant de huit villes aux caractéristiques variées, démontrant sa robustesse et sa capacité à prédire les zones de chaleur avec une précision satisfaisante. Ces travaux illustrent le potentiel de l'intelligence artificielle par rapport aux approches de mesure empirique, en fournissant des outils performants pour la prédiction des UHI.

**Mots clés :** Ilot de Chaleur Urbain, Intelligence Artificielle, Deep Learning, Albedo, MobileNetV2, Carte de Chaleur, Encodeur-Décodeur, Image satellite