

## **CHANGEMENT CLIMATIQUE ET RESURGENCE DE LA PESTE A MADAGASCAR : UNE APPROCHE EXPLORATOIRE BASEE SUR LE DEEP LEARNING**

Parfait Andrianiana RAKOTONINDRAINY, Fidiniaina Mamy RANDRIATSARAFARA, Ndaohialy  
Manda Vy RAVONIMANANTSOA

### **ABSTRACT**

Plague remains endemic in Madagascar, accounting for approximately 75% of global cases reported to the World Health Organization, while climate change increasingly affects environmental conditions linked to disease transmission. Despite this dual challenge, predictive tools integrating climate and epidemiological data remain limited in low-resource settings.

This work introduces an innovative AI-driven climate epidemiology framework designed to improve early warning and decision support for plague outbreaks. We combine 35 years of climate data (1982–2017) from the Analamanga and Bongolava regions with epidemiological surveillance data and environmental indicators (altitude, deforestation, bush fires). Statistical analysis reveals a significant increase in plague incidence associated with temperature anomalies between +2 °C and +2.5 °C and low rainfall (<100 mm). Building on these findings, we propose a deep learning–based predictive model capable of capturing non-linear spatio-temporal interactions between climate, environment, and disease dynamics. The novelty of the approach lies in the integration of heterogeneous data sources and its orientation toward operational use in public health surveillance. This framework aims to support early warning, prevention planning, and climate-resilient health decision-making, demonstrating how artificial intelligence can be translated into actionable innovation for infectious disease control in climate-vulnerable contexts.

**Keywords :** Plague – Climate Change – Deep learning – Health surveillance – Artificial Intelligence

### **FINTINA**

Ny pesta dia mbola mitoetra ho olan'ny fahasalambahoaka eto Madagasikara raha tokoa ka efa foana any amin'ny firenenkafa. Ny 75% ny tranga manerantany dia hita eto Madagasikara raha ny tatitry ny Fikambanana Iraisampirenen'ny Fahasalamana. Mandritra ny vanimpotoana mafana sy isian'ny

rotsakorana, eo anelanelan'ny volana Aogositra sy Aprily no fotoana mampiongatra ny aretina pesta eto Madagasikara indrindra amin'ny faritra avo ety afovoantany. Mifanindrandalana amin'izay, voasokajy ho isan'ireo firenena marefo indrindra amin'ny fiovaovan'ny toetr'andro i Madagasikara. Ity asa fikarohana ity dia mampisongadina ny fiantraikan'ny fiovaovan'ny toetr'andro amin'ny firongatry ny aretina pesta amin'ny fampiasana ny haitao ny Fahaizana tsy voajanahary. ahafahana maminavina mialoha ny fivoaran'ny valan'aretina. Ity asa fikarohana dia nifototra tamin'ny fandinihana antontanisa ny toetry ny andro nandritra ny 35 taona (1982-2017) tao amin'ny Faritry Bongolava sy Analamanga. Ny vokatra dia nampiseho ny fiakaran'ny miandalana ny maripana sy ny fidinan'ny rotsakorana. Ny fandinihana ny tranga ny aretina pesta teo anelanelan'ny taona 2012 sy 2016 no nahitana fa ambony ny trangan'aretina rehefa eo anelanelan'ny  $+2^{\circ}\text{C}$  sy  $+2,5^{\circ}\text{C}$  ny fiakaran'ny maripana ary ny rotsak'orana latsaky ny 100 mm. Voamarina ara-statistika ny fahamarinan'ny vokatra ( $p\text{-value} < 0,05$ ). Mba ahafahana mamantatra mialoha ny firongantany ny valan'aretina, ity asa fikarohana ity dia manolotra vahaolana vaovao mifototra amin'ny fampiasana ny haitao ny Fianarana lalina (Deep Learning) ary mampiasa ny antontanisa ny toetr'andro, (hafanana, rotsakorana), toe-tany (haavo, doro-tanety, fandripahana ny ala) ary ny antontanisa tahiry mikasika ny valan'aretina, ahafahana mamantatra mialoha ny tahan'ny valan'aretina pesta. Ity vahaolana vaovao ity dia natao hanamafy ny fanairana mialoha ny tranga sy ho fanatsarana ny paikady fisorohana ary ny fanaraha-maso ny valan'aretina. Natao ihany koa mba hanampy ny mpanampakevitra ara-pahasalamana amin'ny fandraisana ny fanampahankevitra mahomby sy ho fiantrehan'ny Madagasikara amin'ny fiantraikan'ny fiovaovan'ny toetr'andro.

**Teny fototra :** Pesta – Fiovaovan'ny toetr'andro – Fianarana Lalina (Deep Learning) – Fahalalana tsy voajanahary (Intelligence Articielle)

## **I- INTRODUCTION**

### ***1- Contexte et justification***

La peste, maladie infectieuse causée par *Yersinia pestis*, demeure un problème majeur de santé publique à Madagascar. Le pays figure parmi les principaux foyers mondiaux de cette zoonose et enregistre régulièrement des flambées épidémiques, particulièrement durant la saison chaude et humide qui s'étend généralement d'août à avril. Les Hautes Terres centrales constituent la zone la plus affectée en raison de

conditions écologiques favorables au maintien du cycle de transmission impliquant les rongeurs réservoirs et les puces vectrices.

De nombreuses études ont montré que les facteurs climatiques, notamment la température, la pluviométrie et les anomalies climatiques, influencent fortement la dynamique de transmission de la peste. Les variations climatiques peuvent affecter la survie et la reproduction des vecteurs, modifier les habitats des réservoirs animaux et favoriser les interactions entre les populations humaines et les espèces impliquées dans le cycle épidémiologique.

Dans un contexte marqué par l'accélération du changement climatique, l'identification précoce des conditions favorables à la survenue des flambées de peste constitue un enjeu majeur pour les systèmes de surveillance sanitaire. Toutefois, les relations entre climat, environnement et incidence de la maladie demeurent complexes et souvent non linéaires.

Les méthodes statistiques conventionnelles présentent certaines limites pour analyser ces interactions complexes, en particulier lorsqu'il s'agit d'intégrer simultanément des données climatiques, environnementales et épidémiologiques provenant de sources multiples. Les techniques de deep learning offrent de nouvelles perspectives grâce à leur capacité à modéliser des relations non linéaires, à traiter des données massives et à améliorer la précision des prédictions.

Dans ce contexte, cette étude explore l'utilisation du deep learning pour analyser l'influence du changement climatique sur la résurgence de la peste à Madagascar et développer un modèle prédictif destiné à renforcer les systèmes d'alerte précoce.

## ***2- Problématiques***

Comment le climat influence-t-il la dynamique de la peste ?

Comment les méthodes de Deep Learning peuvent-elles améliorer la compréhension et la prédiction des impacts du changement climatique sur la résurgence de la peste à Madagascar ?

## ***3- Hypothèse de recherche***

H1 : Les variables climatiques influencent significativement la dynamique de la peste à Madagascar selon des relations non linéaires.

H2 : L'intégration conjointe de données climatiques, environnementales et épidémiologiques améliore la capacité de prédiction des zones et périodes à risque.

#### 4- Objectifs

##### a. Objectif général

Évaluer la contribution du Deep Learning dans l'analyse et la prédiction de la résurgence de la peste liée au changement climatique à Madagascar.

##### b. Objectifs spécifiques

- Analyser l'évolution spatio-temporelle des cas de peste en relation avec les variables climatiques.
- Identifier les facteurs climatiques déterminants.
- Développer des modèles prédictifs basés sur le Deep Learning.

#### 5- Revue bibliographique

Voici une sélection d'articles scientifiques et de travaux de recherche pertinents sur l'utilisation de l'Intelligence Artificielle (IA), du Machine Learning et du Deep Learning pour étudier les impacts du changement climatique sur les maladies infectieuses, notamment la peste (*Yersinia pestis*).

##### **1. Assessing plague risk across seven decades of environmental change in Inner Mongolia, China: An interpretable machine learning**

Publié dans *iScience (Elsevier)*, 2026

Cette étude est particulièrement proche de cette étude.

Les chercheurs utilisent le **Machine Learning interprétable (SHAP, GAM)** pour analyser les relations non linéaires entre :

- climat,
- précipitations,
- occupation du sol,
- activités humaines,
- et résurgence de la peste.

## ***2. A review of artificial intelligence for predicting climate driven infectious disease outbreaks to enhance global health resilience***

Publié dans *Discover Public Health (Springer)*, 2025

Il explique comment :

- les réseaux de neurones,
- Random Forest,
- SVM,
- LSTM,
- Transformers

sont utilisés pour prédire les maladies influencées par le climat.

## **II- MATERIELS ET METHODE**

### ***1- Zone d'étude***

Cette étude a été réalisée dans les régions d'Analamanga et de Bongolava, situées dans les Hautes Terres centrales de Madagascar. Ces régions figurent parmi les principaux foyers endémiques de peste du pays et enregistrent régulièrement des cas humains au cours de la saison de transmission.

L'aire d'étude couvre à la fois des zones urbaines et rurales afin de prendre en compte la diversité des contextes écologiques, climatiques et socio-environnementaux susceptibles d'influencer la dynamique de la maladie.



Figure 1 : Carte de la zone d'étude

**2- Données épidémiologique** : Fiche officielle de déclaration individuelle de cas de peste [Annexe1]

A Madagascar, la peste est une maladie à déclaration obligatoire. En cas de suspicion de maladie, une fiche officielle de déclaration individuelle de cas de Peste est remplie par l'agent de santé de la Formation Sanitaire et envoyée au Laboratoire Central de la Peste du Ministère de la Santé (LCP, situé à l'Institut Pasteur de Madagascar, Antananarivo) où sont enregistrées toutes les informations cliniques et épidémiologiques à savoir :

- Confirmation de cas (bubonique / pulmonaire)
- Localisation géographique (Région/ District/ Commune/ Fokontany/ Hameau)

**3- Données climatiques** : Base de données météorologique de la DGM de Madagascar

A Madagascar, la Direction Générale de la Météorologie est l'institution officielle qui détient et fournit les données météorologiques nationales notamment :

- Température (minimale, maximale, moyenne) par localité ((Région/ District/ Commune/ Fokontany)
- Pluviométrie (minimale, maximale, moyenne) par localité ((Région/ District/ Commune/ Fokontany)

**4- Données environnementales** : Base de données environnementale du Ministère de l'Environnement

A Madagascar, le Ministère de l'Environnement est l'institution officielle qui détient et fournit les données environnementales du pays notamment :

- La situation de feux de brousse
- La situation de déforestation

**5- Test statistique : Chi-2**

Le test du Chi-2 (Chi carré) est la méthode statistique utilisée pour vérifier s'il existe une relation significative entre les variables climato-environnementales, et présence de cas de peste.

**6- Préparation de données**

Les données utilisées sont

- Données climatiques (température/ pluviométrie) de la Région de Bongolava de 1982 à 2017
- Données climatiques (température/ pluviométrie) de la Région d'Analamanga (Antananarivo Renivohitra / Ambohidratrimo) de 1989 à 2018
- Cas de peste de 1995 à 2022
- Situation de feux de brousse dans la région de Bongolava et du province d'Antananarivo de 1979 à 1986

De travail préliminaire a été effectué afin de normaliser les données pour être exploitable entre autre le nettoyage de données manquantes

### 7- Modélisation Deep Learning

La méthode d'apprentissage supervisé du Deep Learning a été utilisée




Figure 2: Modèle perceptron simple

### Paramètres du modèle Deep Learning

Nombre de variable d'entrée : 4 (anomalie thermique, pluviométrie, altitude, occupation du sol)

Nombre de variable de sortie : 1 (incidence peste°)

Nombre de couche cachée : 3 (neurones :8-8-6)

Fonction d'activation : Sigmoid

Nombre de couche : 3

Fonction de perte : Erreur quadratique moyenne (pour mesurer l'écart entre les valeurs prédites par le modèle et les valeurs réelles)

Optimiseur : SGD (Stochastic Gradient Descent)

Métriques d'évaluation : Taux d'erreur / Accuracy/ Recall/ F1-score/ AUC-ROC,

## Préparation de données

Les données ont été réparties en trois ensembles :

- apprentissage : 1995–2005 ;
- test : 2006–2015 ;
- validation : 2016–2022.

## Architecture du modèle Deep Learning




Figure 3 : Architecture du modèle de prédiction Deep Learning

Cette figure représente l'architecture du modèle Deep Learning de prédiction de cas de peste en fonction des paramètres climato-environnementale.

### 8- Outils de modélisation : TensorFlow

TensorFlow a été choisi pour cette étude en raison de sa robustesse, de sa flexibilité et de ses performances dans la modélisation des réseaux de neurones profonds. Cette bibliothèque open source facilite la

construction, l'entraînement et l'évaluation de modèles de Deep Learning adaptés à l'analyse des relations complexes entre variables climatiques et incidence de la peste.

Le choix de TensorFlow pour la mise en place d'un modèle de Deep Learning se justifie par plusieurs avantages scientifiques et techniques :

a. *Bibliothèque spécialisée en Deep Learning*

TensorFlow est une plateforme open source développée par Google, conçue spécifiquement pour créer, entraîner et déployer des réseaux de neurones profonds.

b. *Facilité de modélisation*

Il permet de construire facilement des architectures complexes de Deep Learning :

- réseaux de neurones multicouches ;
- CNN ;
- RNN/LSTM ;

c. *Compatibilité avec Python*

TensorFlow fonctionne principalement avec le langage Python, largement utilisé en science des données et en intelligence artificielle.

d. *Performance élevée*

Il optimise les calculs grâce à l'utilisation du GPU et permet de traiter rapidement de grandes quantités de données climatiques ou sanitaires.

e. *Outils intégrés pour l'apprentissage*

TensorFlow intègre :

- des fonctions de perte ;
- des optimiseurs (SGD, Adam, RMSprop) ;
- des métriques d'évaluation comme Accuracy, Recall et F1-score.

f. *Bonne précision des prédictions*

Grâce à sa capacité à apprendre des relations complexes et non linéaires, TensorFlow est adapté à l'analyse des interactions entre variables climatiques et incidence de la peste.

g. *Large communauté scientifique*

TensorFlow bénéficie d'une importante communauté internationale, facilitant :

- l'accès à la documentation ;
- les exemples de code ;
- les publications scientifiques ;
- le support technique.

h. *Visualisation et suivi du modèle*

Avec des outils comme TensorBoard, il permet de suivre :

- l'évolution de l'apprentissage ;
- les performances du modèle ;
- les erreurs et métriques d'évaluation.

**9- Comparaison du modèle MLP aux approches statistiques classiques**

Les méthodes statistiques classiques restent utiles, mais présentent certaines limites :

- elles supposent souvent des relations linéaires,
- elles sont moins performantes avec des données complexes et hétérogènes,
- et leur capacité à modéliser les dynamiques spatio-temporelles est limitée.

En revanche, le Deep Learning :

- capture automatiquement les patterns complexes,
- s'adapte à des volumes de données importants,
- et offre une meilleure capacité de généralisation.

Le Deep Learning constitue un outil particulièrement adapté à l'épidémiologie climatique

Le tableau 1 représente la comparaison du modèle Deep Learning de type Multi Layer Perceptron aux approches statistiques classiques

10- Tableau 1 : Comparaison du modèle MLP aux approches statistiques classiques

| Critère                | Approche statistique classique | Deep Learning                                               |
|------------------------|--------------------------------|-------------------------------------------------------------|
| Relation des variables | Souvent linéaire               | Capture automatique des variables complexes et non linéaire |

|                              |                                                           |                                                  |
|------------------------------|-----------------------------------------------------------|--------------------------------------------------|
| Performance de prédiction    | Bon pour les phénomènes simples                           | Généralement supérieur pour le système complexes |
| Big Data                     | Performance limitée pour le volume de données importantes | Excellente capacité pour exploiter les Big Data  |
| Nombre de variable           | Sensible à la multicollinéarité                           | Gestion efficace d'un grand nombre de variable   |
| Modélisation spatio-temporel | Limitée                                                   | Hautement effectif                               |

### 11- Comparaison des modèles : MLP/ RNN/ LSTM

Le tableau 2 représente la comparaison des différents modèles Deep Learning

Tableau 2: Comparaison des modèles Deep Learning

| Caractéristique                     | MLP (Multi-Layer Perceptron) | RNN (Recurrent Neural Network) | LSTM (Long Short-Term Memory) |
|-------------------------------------|------------------------------|--------------------------------|-------------------------------|
| Type de données                     | Données tabulaires           | Données séquentielles          | Données séquentielles         |
| Mémoire du passé                    | ✗ Non                        | ✓ Oui                          | ✓ Oui (améliorée)             |
| Complexité                          | Faible                       | Moyenne                        | Élevée                        |
| Temps de calcul                     | Rapide                       | Plus lent                      | Plus lent                     |
| Gestion des dépendances temporelles | Faible                       | Moyenne                        | Excellente                    |
| Risque de perte d'information       | Non concerné                 | Élevé                          | Faible                        |

### 12- Pourquoi le choix du MLP (Multi Layer Perceptron) ?

MLP a été choisi pour cette étude car les données étaient structurées sous forme de variables explicatives agrégées et le nombre d'observations était relativement limité. Le MLP permet de

modéliser efficacement des relations non linéaires tout en restant plus simple et moins coûteux à entraîner qu'un LSTM. L'utilisation d'un LSTM aurait été davantage justifiée si nous avions disposé de longues séries temporelles et souhaité modéliser explicitement les dépendances séquentielles entre observations.

### III- RESULTATS

#### Évolution des paramètres climatiques

La figure 4 montre que l'anomalie thermique du mois de décembre augmente continuellement depuis 35 ans pour la région de Bongolava.




Figure 4: Courbe de tendance d'anomalie de température du mois de Décembre pour les 35 dernières années (1982-2016) pour la région de Bongolava

La figure 5 montre que la pluviométrie du mois de décembre diminue continuellement depuis 35 ans pour la région de Bongolava.




Figure 5: Courbe de tendance de la pluviométrie du mois de Décembre pour les 35 dernières années (1982-2016) pour la région de Bongolava

Ces résultats confirment la présence d'une tendance climatique caractérisée par un réchauffement progressif associé à une réduction des précipitations.

### Relation entre climat et incidence de la peste




Figure 6: Evolution du nombre de cas de peste par rapport à l'anomalie thermique durant la période de 2012 à 2016 pour la région Bongolava




Figure 7: Evolution du nombre de cas de peste par rapport à la pluviométrie durant la période de 2012 à 2016 pour la région Bongolava

L'analyse des cas de peste enregistrés entre 2012 et 2016 montre que les incidences les plus élevées sont observées lorsque les anomalies thermiques se situent entre +2 °C et +2,5 °C.

Une augmentation importante du nombre de cas est également observée lorsque la pluviométrie est inférieure à 100 mm.

Ces observations suggèrent l'existence d'un seuil climatique favorable à la transmission de la maladie.

### Résultats du test statistique

Hypothèse nulle (Ho) : La recrudescence de peste ne dépend pas de l'anomalie climatique.

Hypothèse alternative (H1) : L'anomalie climatique (anomalie thermique entre [2°C, 2,5°C[ à une pluviométrie inférieure à 100mm) et la recrudescence de cas de peste sont liées.

On pose le seuil  $\alpha$  (risque de première espèce) à 5%.

Tableau 3: Tableau de contingence (Données de Bongolava de 2012 à 2016 sur 325 cas notifiés)

|                                      | CONFIRME | NON CONFIRME | Taux de cas confirmé |
|--------------------------------------|----------|--------------|----------------------|
| Anomalie de Température [2°C, 2,5°C[ | 101      | 36           | 73,72%               |
| Pluviométrie inférieure à 100 mm     | 138      | 28           | 83,13%               |

Le test du Chi carré a mis en évidence une association statistiquement significative entre les anomalies climatiques et les cas de peste.

Les résultats obtenus montrent :

- $\chi^2 = 3,99$  ;
- p-value < 0,05.

L'hypothèse nulle a donc été rejetée au seuil de signification de 5 %, indiquant que les anomalies climatiques étudiées sont associées à la dynamique de la peste dans les régions analysées.

### Performances du modèle Deep Learning (Multi Layer Perceptron)

Le tableau 1 représente le résultat de l'apprentissage du modèle TensorFlow de type MLP avec trois (03) couches.

Le tableau 4 représente le résultat de l'apprentissage du modèle TensorFlow de type MLP à 3 couches.

Tableau 4 : Résultat de l'apprentissage du modèle TensorFlow de type MLP à trois (03) couches

| Pas d'apprentissage | Nombre de couches | Taux d'erreur | Nombre d'itérations |
|---------------------|-------------------|---------------|---------------------|
| 1                   | 3                 | 17,08%        | 1 000               |
| 0.5                 | 3                 | 17.09%        | 500                 |
| 0.1                 | 3                 | 17.32%        | 250                 |
| 0.01                | 3                 | 17.84%        | 100                 |

### Résultat de l'évaluation du modèle

Le tableau 5 représente le résultat de l'évaluation du modèle par l'échantillon test

Tableau 5: Résultat de l'évaluation du modèle par l'échantillon test

| Pas d'apprentissage | Nombre de couches | Taux d'erreur | Nombre d'itérations |
|---------------------|-------------------|---------------|---------------------|
| (Learning rate)     | (Layer number)    | (Cost)        | (Epoch)             |
| 1                   | 3                 | 17,26%        | 1 000               |

Le modèle MLP a obtenu les performances suivantes lors de l'évaluation :

- Accuracy : 83 % ;
- Recall : 82 % ;

- F1-score : 83 % ;
- AUC-ROC : 0,88 ;
- Taux d'erreur : 17,26 %.




Figure 8: Courbe d'apprentissage du modèle

Ces résultats indiquent une capacité satisfaisante du modèle à identifier les conditions associées à la survenue des cas de peste.

#### IV- DISCUSSIONS

Les résultats de cette étude montrent une relation significative entre le changement climatique et la résurgence de la peste. L'analyse des données sur 35 ans révèle une augmentation progressive des températures et une diminution des précipitations.

Les cas de peste sont particulièrement élevés lorsque l'anomalie thermique se situe entre +2°C et +2,5°C et lorsque la pluviométrie est inférieure à 100 mm. Le test du Chi-2 confirme une association statistiquement significative entre les anomalies climatiques et les cas de peste (p-value < 0,05).

Plusieurs mécanismes peuvent expliquer cette relation. L'augmentation des températures peut favoriser la prolifération des puces vectrices ainsi que les déplacements des rongeurs réservoirs. De même, la diminution des précipitations (stress écologique) pourrait modifier les habitats naturels et augmenter les contacts entre les rongeurs et la population humaine. Ces observations rejoignent plusieurs travaux internationaux montrant l'influence du climat sur les maladies zoonotiques et vectorielles.

L'utilisation du Deep Learning constitue un apport innovant de cette étude. Les réseaux de neurones artificiels permettent de mieux modéliser les relations complexes entre climat, environnement et épidémie. Le modèle MLP a obtenu un taux d'erreur de 17,26 %, correspondant à une précision globale de 83 %. Dans le contexte de la surveillance épidémiologique et des systèmes d'alerte précoce, ce niveau de performance est considéré comme satisfaisant, particulièrement compte tenu de la complexité des interactions climat-environnement-maladie et des limitations des données disponibles. Toutefois, cette marge d'erreur indique qu'une amélioration du modèle demeure possible par l'intégration de variables supplémentaires (socio-économique, comportementale), de séries temporelles plus longues et de méthodes avancées telles que les architectures RNN ou LSTM.

Une des principales limites de cette étude concerne la taille relativement réduite de l'échantillon utilisé pour l'apprentissage du modèle. En effet, les données d'entraînement couvrent la période 1995–2005, soit un nombre limité d'observations comparativement aux standards habituellement requis pour les applications de Deep Learning. Les réseaux de neurones artificiels sont généralement plus performants lorsqu'ils sont entraînés sur de grands volumes de données permettant de capturer une large diversité de situations climatiques et épidémiologiques.

Cette contrainte peut affecter la capacité de généralisation du modèle, c'est-à-dire son aptitude à produire des prédictions fiables dans des contextes différents de ceux observés durant la phase d'apprentissage. Un nombre limité d'observations augmente notamment le risque de surapprentissage (overfitting), situation dans laquelle le modèle apprend les particularités du jeu d'entraînement sans être capable de reproduire ses performances sur de nouvelles données.

Toutefois, plusieurs éléments permettent de relativiser cette limitation. Premièrement, les données utilisées couvrent différentes situations climatiques et épidémiologiques observées dans deux des principaux foyers pesteux (Bongolava, Analamanga) de Madagascar, offrant une variabilité suffisante pour une étude exploratoire. Deuxièmement, l'objectif principal de ce travail était de démontrer la faisabilité d'une approche basée sur le Deep Learning dans le contexte de la surveillance climatique de la peste plutôt que de développer un modèle opérationnel définitif.

Par ailleurs, les performances obtenues lors de l'évaluation (Accuracy = 83 %, Recall = 82 % et F1-score = 83 %) suggèrent que le modèle est capable de capturer une partie significative des relations entre les variables climatiques et la dynamique de la peste malgré la limitation des données disponibles. Néanmoins, ces résultats doivent être interprétés avec prudence et nécessitent une validation supplémentaire sur des jeux de données indépendants couvrant d'autres régions et périodes climatiques. Cette étude présente certaines limites, notamment une faible taille de l'échantillon de données, la présence de données manquantes ainsi qu'une couverture géographique limitée, pouvant influencer la précision et la généralisation des résultats obtenus.

Malgré certaines limites liées à la disponibilité des données et au nombre limité de régions étudiées, cette recherche montre que l'intelligence artificielle peut devenir un outil stratégique d'aide à la décision pour la surveillance et la prévention de la peste à Madagascar.

Enfin, l'intégration de variables supplémentaires, notamment socio-économiques et comportementales, pourrait améliorer davantage la précision des prédictions.

En termes de perspectives, plusieurs axes peuvent être envisagés :

- l'utilisation de modèles plus avancés, comme les RNN ou LSTM,
- l'intégration de données en temps réel,
- et le développement d'outils opérationnels directement utilisables par les systèmes de surveillance.

## V- CONCLUSION

Cette étude a permis de mettre en évidence l'influence significative des facteurs climatiques sur la résurgence de la peste à Madagascar. L'analyse des données climatiques et épidémiologiques a montré qu'une augmentation des anomalies thermiques ainsi qu'une diminution de la pluviométrie sont associées à une augmentation des cas de peste dans les régions étudiées.

Les résultats du test statistique Chi-2 ont confirmé l'existence d'une relation significative entre les anomalies climatiques et les cas de peste. Ces résultats renforcent l'hypothèse selon laquelle le changement climatique constitue un facteur important dans la dynamique épidémiologique de cette maladie endémique.

D'après la revue bibliographique, cette recherche propose une approche exploratoire innovante basée sur le Deep Learning afin de modéliser les interactions spatio-temporelles non linéaires entre climat et dynamique épidémique. Le modèle combine des données climato-environnementales et épidémiologiques historiques afin de prédire la prévalence de la peste dans le temps et l'espace. Cette approche d'épidémiologie climatique vise à renforcer l'alerte précoce, la stratégie de prévention et améliorer la surveillance épidémiologique.

Quelles sont les contributions de cette recherche ?

#### ➤ **Contributions scientifiques**

Cette étude apporte plusieurs contributions majeures :

- Identification d'un seuil climatique critique :

[anomalie thermique entre +2 et +2,5 °C associée à une faible pluviométrie (<100 mm)]

- Mise en évidence de relations non linéaires entre climat et peste
- Intégration d'une approche One Health multi-sources
- Développement d'un prototype d'outil de prédiction du risque

Ce travail établit un lien opérationnel entre science du climat, intelligence artificielle et santé publique.

#### ➤ **Implications pour la santé publique**

Les implications de ces résultats sont directes et importantes.

Ils permettent notamment de :

- renforcer les systèmes de surveillance épidémiologique,
- développer des systèmes d'alerte précoce basés sur le climat,
- mieux cibler les interventions de prévention,
- et améliorer la prise de décision stratégique.

À terme, cela contribue à une meilleure préparation face aux épidémies dans un contexte de changement climatique.

Les perspectives de cette étude incluent l'extension des analyses à d'autres régions, l'intégration de données satellitaires en temps réel et la création d'un système national d'alerte précoce. L'intégration de variables supplémentaires, notamment socio-économiques et comportementales, pourrait améliorer davantage la précision des prédictions. En combinant l'intelligence artificielle, les données climatiques et la santé publique, cette solution peut devenir un outil stratégique d'aide à la décision sanitaire et contribuer concrètement à la résilience de Madagascar face au changement climatique. La technologie apparaît ainsi comme un levier concret pour protéger des vies.

## FIGURES

Figure 1: Carte de la zone d'étude

Figure 2: Modèle perceptron simple

Figure 3: Architecture du modèle de prédiction Deep Learning

Figure 4: Courbe de tendance d'anomalie de température du mois de Décembre pour les 35 dernières années (1982-2016) pour la région de Bongolava

Figure 5: Courbe de tendance de la pluviométrie du mois de Décembre pour les 35 dernières années (1982-2016) pour la région de Bongolava

Figure 6: Evolution du nombre de cas de peste par rapport à l'anomalie thermique durant la période de 2012 à 2016 pour la région Bongolava

Figure 7: Evolution du nombre de cas de peste par rapport à la pluviométrie durant la période de 2012 à 2016 pour la région Bongolava

Figure8 : Courbe d'apprentissage du modèle

## TABLEAUX

Tableau 1 : Comparaison du modèle Deep Learning de type Multi Layer Perceptron aux approches statistiques classiques

Tableau 2: Comparaison des différents modèles Deep Learning

Tableau 3 : Tableau de contingence

Tableau 4 : Résultat de l'apprentissage du modèle TensorFlow de type MLP à trois (03) couches

Tableau 5: Résultat de l'évaluation du modèle par l'échantillon test