

Evaluation Des Gains A Court Terme Des Prédicteurs Microclimatiques Lies Aux Murs Végétalisés Dans La Prédiction Neuronale De L'intensité Cyclonique Du SWIO

RAJAONARISON Lalaina Dina^{1,1}, RAJAONARISON Eddie Frank^{1,2}, RAKOTOSON Andriatiana Tolontsoa^{1,3}, TOVONIRINA Mamiharizo Jackie^{1,4}

^{1,2,3,4}Ecole Doctorale Ingénierie et Géosciences - Université d'Antananarivo

Auteur correspondant: RAKOTOSON Andriatiana Tolontsoa, andriatianatolo@gmail.com



Résumé: Les cyclones tropicaux du sud-ouest de l'océan Indien constituent une menace majeure pour les territoires côtiers, ce qui exige des prévisions d'intensité à la fois précises, robustes et interprétables. Cette étude évalue l'apport de prédicteurs microclimatiques liés aux murs végétalisés dans un réseau de neurones artificiels destiné à prévoir la vitesse maximale du vent entre 12 et 72 h. Deux configurations sont comparées : un RNA de référence et un RNA enrichi par les variables du mur. À 12 et 24 h, le modèle enrichi réduit respectivement la RMSE de 2,9 % et 2,7 %, la MAE de 3,6 % et 2,5 %, ainsi que le sMAPE de 5,0 % et 3,5 %. À 48 h, les gains restent modestes, avec 1,5 % sur la RMSE et 0,9 % sur la MAE. En revanche, à 72 h, la RMSE augmente de 8,8 %, la MAE de 9,0 % et le score d'habileté diminue de 18,5 %. À 24 h, l'accuracy avoisine 0,73 pour les deux modèles, mais le F1 macro est plus faible avec mur, soit 0,62 contre 0,70. Ces résultats montrent un bénéfice surtout limité aux courtes échéances.

Mots-clés : Murs Végétalisés ; Microclimat ; Réseaux De Neurones Artificiels ; Cyclones Tropicaux ; SWIO.

Abstract: Tropical cyclones in the South-West Indian Ocean represent a major threat to coastal territories, requiring intensity forecasts that are accurate, robust, and interpretable. This study evaluates the contribution of microclimatic predictors associated with green walls to an artificial neural network designed to forecast maximum wind speed from 12 to 72 h. Two configurations were compared: a baseline neural network and an enhanced model incorporating green-wall-related variables. At 12 and 24 h, the enhanced model reduced RMSE by 2.9% and 2.7%, MAE by 3.6% and 2.5%, and sMAPE by 5.0% and 3.5%, respectively. At 48 h, the improvements remained modest, with reductions of 1.5% in RMSE and 0.9% in MAE. By contrast, at 72 h, RMSE increased by 8.8%, MAE by 9.0%, and the skill score decreased by 18.5%. At 24 h, classification accuracy was approximately 0.73 for both models, whereas the macro-F1 score was lower for the enhanced model, reaching 0.62 compared with 0.70 for the baseline model. Overall, the findings indicate that green-wall-related microclimatic predictors provide limited benefits, mainly at short forecast lead times.

Keywords: Green Walls; Microclimate; Artificial Neural Networks; Tropical Cyclones; SWIO.

1. INTRODUCTION

Les cyclones tropicaux figurent parmi les phénomènes météorologiques les plus destructeurs dans le sud-ouest de l'océan Indien (SWIO), où ils menacent régulièrement les populations, les infrastructures et les écosystèmes côtiers de Madagascar, du Mozambique, des Comores, de Maurice, de La Réunion et des Seychelles. Dans ce bassin, l'énergie thermique disponible dans la couche supérieure de l'océan joue un rôle déterminant dans le maintien et l'intensification des systèmes cycloniques. La variabilité interannuelle du contenu thermique océanique contribue ainsi à modifier les conditions favorables au développement des cyclones, ce qui complexifie l'anticipation de leur évolution [1]. La prévision de l'intensité demeure généralement plus

difficile que celle de la trajectoire. Cette difficulté résulte des interactions non linéaires entre la dynamique interne du cyclone, le cisaillement vertical du vent, l'humidité atmosphérique, la température de surface de la mer et la structure thermique de l'océan supérieur. Dans le SWIO, les épisodes d'intensification peuvent notamment être favorisés par une couche océanique chaude profonde, une couche barrière épaisse et la présence de tourbillons anticycloniques. Ces mécanismes agissent à des échelles spatiales et temporelles différentes et limitent la capacité des modèles à reproduire précisément les variations de la vitesse maximale du vent [2]. Les modèles statistiques opérationnels de prévision de l'intensité s'appuient traditionnellement sur des variables de persistance, de climatologie et d'environnement atmosphérique ou océanique. Le modèle SHIPS, par exemple, combine l'intensité initiale du cyclone avec plusieurs prédicteurs décrivant son environnement afin d'estimer son évolution à différentes échéances. Malgré les améliorations apportées à ces approches, leurs performances diminuent généralement lorsque l'horizon de prévision s'allonge, notamment en raison de l'incertitude associée aux conditions initiales, aux interactions océan-atmosphère et aux changements rapides d'intensité [3]. Dans ce contexte, les réseaux de neurones artificiels constituent une approche pertinente pour représenter des relations complexes entre les variables prédictives et l'intensité cyclonique. Contrairement aux modèles de régression strictement linéaires, les RNA peuvent apprendre des interactions non linéaires sans qu'une forme fonctionnelle unique soit imposée à l'avance. Baik et Paek ont notamment développé un RNA à rétropropagation pour prévoir les changements d'intensité à 12, 24, 36, 48, 60 et 72 h. Leur modèle, alimenté par des variables de climatologie, de persistance et d'environnement synoptique, a produit des erreurs moyennes inférieures de 7 à 16 % à celles d'un modèle de régression multiple utilisant les mêmes prédicteurs [4]. Les développements récents de l'apprentissage profond confirment le potentiel des méthodes neuronales pour intégrer des sources de données hétérogènes et améliorer la représentation des mécanismes associés à l'intensification cyclonique. Ces performances restent toutefois fortement dépendantes de la pertinence des variables d'entrée, de la qualité des observations, de la stratégie de validation et de la représentativité des événements extrêmes dans les données d'apprentissage [5]. La sélection des prédicteurs constitue donc une étape essentielle afin de réduire la redondance, de limiter le surajustement et d'identifier les variables apportant une information réellement complémentaire. Parallèlement, les murs végétalisés sont de plus en plus étudiés comme dispositifs passifs de régulation du microclimat urbain. Leur fonctionnement repose principalement sur l'ombrage, l'évapotranspiration, la création d'une couche d'air entre la végétation et la façade, ainsi que l'augmentation de la résistance thermique de l'enveloppe. Ces mécanismes peuvent modifier localement la température de surface, la température de l'air, l'humidité et les échanges de chaleur à proximité des bâtiments [6]. Les performances observées dépendent néanmoins du système végétalisé, des espèces utilisées, de l'épaisseur du substrat, de l'orientation de la façade et des conditions climatiques locales. Des expérimentations conduites en climat tropical ont montré que certains systèmes de végétalisation verticale réduisent la température des surfaces murales et atténuent leurs fluctuations diurnes. Leur influence sur la température ambiante est toutefois spatialement limitée et varie fortement selon la configuration étudiée ; dans une étude expérimentale portant sur huit systèmes, l'effet thermique de certaines configurations était encore détectable à environ 0,60 m de la paroi, tandis que d'autres produisaient peu de changement mesurable [7]. Ces résultats montrent que les murs végétalisés génèrent avant tout un signal microclimatique local et ne permettent pas, en l'état des connaissances, de supposer une modification directe de la dynamique ou de l'intensité physique d'un cyclone tropical. La question scientifique pertinente consiste donc à déterminer si les variations locales de température, d'humidité, de pression et de vent associées aux murs végétalisés peuvent apporter une information complémentaire à un modèle neuronal de prévision. La présente étude vise ainsi à évaluer les gains à court terme de prédicteurs microclimatiques liés aux murs végétalisés dans la prévision de la vitesse maximale du vent des cyclones tropicaux du SWIO. Deux configurations sont comparées entre 12 et 72 h : un RNA de référence fondé sur les variables cycloniques et météorologiques conventionnelles, et un RNA enrichi par les variables microclimatiques associées au mur végétalisé. Les prédicteurs sont hiérarchisés afin de ne conserver que les variables les plus informatives, puis les modèles sont évalués à l'aide d'indicateurs de précision, d'habileté, d'incertitude, de diagnostic des résidus et de classification des intensités. Cette démarche permet de déterminer si l'information microclimatique apporte un gain robuste, d'identifier les échéances auxquelles ce gain apparaît et d'examiner les éventuelles dégradations selon la classe d'intensité cyclonique.

2. MATÉRIELS ET MÉTHODES

Les traitements numériques et statistiques ont été réalisés sous Python 3, dans un environnement reproductible adapté à la manipulation de données météorologiques et à l'apprentissage automatique. La bibliothèque NumPy a été utilisée pour les

opérations matricielles, la génération des variables synthétiques, la normalisation des tableaux numériques et l'exécution des calculs vectorisés nécessaires à la modélisation [8]. La bibliothèque pandas a servi à importer les fichiers de données, structurer les observations par cyclone et par échéance, vérifier les types de variables, traiter les valeurs manquantes et exporter les résultats sous forme de tableaux CSV [9]. Les graphiques scientifiques ont été produits avec Matplotlib, notamment les courbes de performance, les diagrammes de dispersion, les matrices de confusion, les diagrammes de Taylor, les représentations radar et les planches A4 en disposition deux par deux [10]. SciPy a été employé pour les analyses statistiques complémentaires, en particulier le calcul des corrélations de Pearson et de Spearman, l'étude de la distribution des résidus et la construction des quantiles théoriques utilisés dans les diagrammes Q-Q [11].

Le jeu de données de démonstration a été structuré autour de plusieurs cyclones tropicaux simulés dans le bassin du sud-ouest de l'océan Indien. Chaque cyclone était représenté par une succession d'observations temporelles comprenant les caractéristiques de son intensité, de son déplacement et de son environnement atmosphérique. Les variables cibles correspondaient à la vitesse maximale du vent prévue aux échéances de 12, 24, 36, 48, 60 et 72 heures. Les prédictors conventionnels incluaient successivement la vitesse maximale du vent à l'instant initial, les vitesses observées 6, 12 et 24 heures auparavant, les variations récentes d'intensité, la latitude, les déplacements longitudinal et latitudinal, la vitesse de translation du système, le jour de l'année, l'âge du cyclone, la température de l'air, l'humidité relative, la pression atmosphérique et le cisaillement vertical du vent. Les variables associées aux murs végétalisés ont été intégrées comme indicateurs microclimatiques locaux et non comme facteurs modifiant directement la dynamique du cyclone. Elles comprenaient la présence ou l'absence d'un mur végétalisé, le taux de couverture végétale, l'épaisseur du système, la conductivité thermique des matériaux, le flux thermique de la paroi, la réduction locale de la température, l'augmentation de l'humidité relative et l'atténuation de la vitesse du vent à proximité de la façade. Dans la version synthétique, les échanges thermiques ont été estimés en considérant successivement la convection extérieure, la résistance thermique du mur, la conductivité des couches et la convection intérieure. Le flux de chaleur a ensuite été déterminé à partir de l'écart entre les températures extérieure et intérieure et de la résistance thermique globale du système. Cette représentation simplifiée visait uniquement à produire des prédictors microclimatiques cohérents avec la problématique étudiée. Avant l'entraînement, les variables ont été converties en valeurs numériques et les observations incomplètes pour les prédictors ou les cibles nécessaires ont été retirées. Les données ont ensuite été divisées en ensembles d'apprentissage et de test en tenant compte de l'identité des cyclones. Environ 75 % des systèmes ont été affectés à l'apprentissage et 25 % à l'évaluation finale. La séparation a été effectuée de manière groupée afin qu'un même cyclone ne puisse pas apparaître simultanément dans les deux ensembles. Cette précaution limite les risques de fuite d'information entre des observations temporellement dépendantes et permet une estimation plus réaliste de la capacité de généralisation du modèle. Les principales étapes de préparation, d'entraînement et d'évaluation ont été mises en œuvre avec scikit-learn [12]. Pour chaque échéance, deux configurations ont été construites. La première, appelée RNA sans mur, utilisait uniquement les variables cycloniques, spatio-temporelles et environnementales conventionnelles. La seconde, appelée RNA avec mur, utilisait ces mêmes variables auxquelles étaient ajoutés les indicateurs microclimatiques associés aux murs végétalisés. Un modèle indépendant a été entraîné pour chacune des six échéances et pour chacune des deux configurations, ce qui correspond à douze réseaux de neurones distincts. Chaque réseau reposait sur un perceptron multicouche de régression comportant deux couches cachées. La première couche comprenait 64 neurones et la seconde 32 neurones. Une fonction d'activation rectifiée linéaire a été appliquée entre les couches afin de représenter les relations non linéaires entre les prédictors et la vitesse maximale du vent. Les variables d'entrée ont été standardisées avant l'apprentissage. Cette transformation consistait à centrer chaque variable autour de sa moyenne et à la ramener à une échelle comparable à partir de son écart-type. Les paramètres de standardisation ont été estimés uniquement sur l'ensemble d'apprentissage, puis appliqués sans modification à l'ensemble de test. L'optimisation des poids du réseau a été réalisée avec l'algorithme Adam, qui adapte progressivement le taux d'apprentissage selon la moyenne et la variabilité des gradients calculés pendant l'entraînement [13]. Le taux d'apprentissage initial a été fixé à 0,001 et la taille des lots à 64 observations. Le nombre maximal d'itérations a été limité à 1 500. Une régularisation de type L2 a été appliquée afin de réduire la complexité excessive du modèle et de limiter le surajustement. Une partie de l'ensemble d'apprentissage, représentant 15 % des observations, a été réservée à la validation interne. L'entraînement était interrompu lorsqu'aucune amélioration de la performance de validation n'était observée pendant 35 itérations consécutives. La sélection des variables a été réalisée avec une procédure de

Gram-Schmidt modifiée [14]. Premièrement, les prédicteurs et la variable cible ont été centrés et standardisés. Deuxièmement, la proximité entre chaque prédicteur et la sortie a été évaluée à partir de leur orientation dans l'espace vectoriel. Troisièmement, la variable présentant la plus forte contribution à l'explication de la cible a été sélectionnée. Quatrièmement, l'information déjà expliquée par cette variable a été retirée des prédicteurs restants et de la sortie. Cinquièmement, la procédure a été répétée jusqu'à obtenir un classement complet des variables. Enfin, les quatorze prédicteurs les mieux classés ont été retenus pour l'entraînement de chaque modèle. La sélection a été effectuée exclusivement sur les données d'apprentissage afin d'éviter toute utilisation indirecte des observations de test. La performance continue des modèles a été examinée à l'aide de plusieurs familles d'indicateurs. La première famille regroupait les mesures d'erreur absolue et quadratique, comprenant l'erreur quadratique moyenne, sa racine carrée, l'erreur absolue moyenne, l'erreur absolue médiane et l'erreur maximale. La deuxième famille concernait les mesures relatives, notamment l'erreur absolue moyenne en pourcentage, l'erreur symétrique en pourcentage et l'erreur quadratique normalisée. La troisième famille décrivait le biais et la dispersion des résidus à partir du biais moyen, du biais relatif et de l'écart-type des erreurs. La quatrième famille évaluait la concordance entre les observations et les prévisions à l'aide du coefficient de détermination, de la variance expliquée, des corrélations de Pearson et de Spearman, de l'efficacité de Nash-Sutcliffe, de l'indice d'accord de Willmott et du Kling-Gupta Efficiency. Un score d'habileté a également été calculé en comparant les performances du RNA à celles d'une prévision de persistance utilisant la vitesse maximale du vent à l'instant initial. Les proportions de prévisions situées dans des intervalles de plus ou moins 5 m/s et de plus ou moins 10 m/s ont été calculées, de même que les quantiles 50, 75, 90 et 95 % de l'erreur absolue. L'évaluation catégorielle a reposé sur six classes d'intensité définies à partir de seuils successifs de vitesse du vent. Ces classes correspondaient aux dépressions tropicales, aux tempêtes tropicales modérées, aux fortes tempêtes tropicales, aux cyclones tropicaux, aux cyclones tropicaux intenses et aux cyclones tropicaux très intenses. Les résultats ont été synthétisés par des matrices de confusion normalisées. Les indicateurs calculés comprenaient l'exactitude globale, l'exactitude équilibrée, la précision, le rappel, le score F1 macro, le score F1 pondéré, le coefficient kappa de Cohen et le coefficient de corrélation de Matthews. Une analyse spécifique a également été menée pour détecter les événements dépassant les seuils de 33 et 46 m/s. Elle comprenait le nombre de détections correctes, de fausses alarmes, d'événements manqués et de rejets corrects, ainsi que la probabilité de détection, le taux de fausses alarmes, la spécificité, l'indice de succès critique, le score F1, l'Equitable Threat Score et le Heidke Skill Score. L'incertitude associée aux performances a été estimée par une méthode bootstrap respectant la structure groupée des observations [15]. Les cyclones présents dans l'ensemble de test ont été rééchantillonnés avec remise, chaque cyclone conservant l'ensemble de ses observations. Cette opération a été répétée 300 fois. Pour chaque réplique, les principaux indicateurs, notamment la RMSE, ont été recalculés. Les intervalles de confiance à 95 % ont ensuite été obtenus en retenant les quantiles 2,5 et 97,5 % de la distribution des valeurs produites par le rééchantillonnage. Les visualisations ont été organisées en quatre planches complémentaires. La première comparait les performances générales des modèles selon l'échéance. La deuxième analysait la concordance entre observations et prévisions, la structure des résidus, l'accord entre les méthodes et la normalité des erreurs. La troisième présentait le diagramme de Taylor, les intervalles de confiance bootstrap, la distribution cumulée des erreurs absolues et la performance selon la classe d'intensité. Les résultats issus de cette procédure doivent être considérés comme une démonstration méthodologique lorsque les données synthétiques sont utilisées. Leur validation scientifique nécessite l'application du même protocole à des observations cycloniques réelles du SWIO et à des mesures microclimatiques obtenues expérimentalement à proximité de murs végétalisés. Il conviendra également d'adapter les seuils d'intensité, les paramètres thermiques, la structure du réseau et le nombre de prédicteurs aux caractéristiques du jeu de données réel.

3. RESULTATS ET DISCUSSIONS

3.1 Comparaison multi-échances des performances des RNA avec et sans intégration des variables liées aux murs végétalisés

La figure ci-après présente une évaluation comparative des performances du RNA de référence et du RNA intégrant les variables microclimatiques associées aux murs végétalisés. L'analyse porte sur six échéances de prévision, comprises entre 12 et 72 heures, et mobilise plusieurs indicateurs complémentaires, notamment la RMSE, la MAE, le sMAPE, le NRMSE, le coefficient de détermination R^2 , l'efficacité de Nash-Sutcliffe, le KGE et le score d'habileté. La matrice des gains quantifie l'amélioration

relative apportée par le modèle avec mur, tandis que le diagramme radar synthétise son profil de performance à l'échéance de 24 heures.

Tableau de bord global des performances RNA - SWIO




Figure 1: Comparaison multi-échances des performances des RNA avec et sans intégration des variables liées aux murs végétalisés

Source : Auteur

Interprétation

Les résultats montrent une augmentation progressive des erreurs avec l'allongement de l'échéance de prévision. Pour le RNA sans mur, la RMSE passe approximativement de 4,2 m/s à 12 h à 8,4 m/s à 72 h, tandis que celle du RNA avec mur évolue de 4,1 à 9,1 m/s. L'intégration des variables liées au mur végétalisé améliore les prévisions aux échéances de 12 h et 24 h, avec des réductions respectives de la RMSE de 2,9 % et 2,7 %, de la MAE de 3,6 % et 2,5 %, ainsi que du sMAPE de 5,0 % et 3,5 %. Une amélioration plus modérée est également observée à 48 h, avec des gains de 1,5 % pour la RMSE et de 0,9 % pour la MAE. En revanche, les performances se dégradent à 36 h, 60 h et surtout 72 h, où la RMSE augmente de 8,8 %, la MAE de 9,0 % et le score d'habileté diminue de 18,5 %. Les coefficients R^2 , NSE et KGE restent globalement élevés, mais décroissent avec l'échéance, traduisant une perte progressive de capacité prédictive. Le profil radar à 24 h confirme que les deux modèles présentent des performances proches, avec un léger avantage global en faveur du RNA intégrant les variables du mur. Ces résultats suggèrent que l'apport des murs végétalisés est principalement pertinent pour les prévisions à court terme, alors que leur contribution devient limitée, voire défavorable, aux échéances les plus longues.

3.2 Diagnostic comparatif des erreurs des RNA avec et sans variables liées aux murs végétalisés à l'échéance de 24 heures

La figure ci-après examine la qualité des prévisions de la vitesse maximale du vent à 24 heures à partir de quatre diagnostics complémentaires : la concordance entre les valeurs observées et prédites, la structure des résidus, le diagramme de Bland-Altman et le Q-Q plot. Ces représentations permettent d'évaluer simultanément la précision, le biais, la dispersion et la distribution statistique des erreurs produites par les deux configurations du RNA.




Figure 2: Diagnostic comparatif des erreurs des RNA avec et sans variables liées aux murs végétalisés à l'échéance de 24 heures

Source : Auteur

Interprétation

Les valeurs prédites sont globalement proches de la ligne d'identité sur une gamme d'intensités comprise approximativement entre 10 et 95 m/s, ce qui traduit une bonne concordance avec les observations. La majorité des résidus se situe entre -10 et +10 m/s, bien que quelques erreurs extrêmes atteignent environ -15 et +15 m/s. Les courbes de tendance révèlent un léger biais négatif pour les intensités intermédiaires, suivi d'une surestimation progressive lorsque la vitesse prédite dépasse environ 60 m/s. Cette tendance est moins marquée pour le RNA intégrant les variables du mur végétalisé, dont les résidus restent plus proches de zéro aux fortes intensités. Le diagramme de Bland-Altman indique, pour les deux modèles, un biais moyen très faible et légèrement négatif, proche de 0 m/s. Les limites d'accord à 95 % sont approximativement comprises entre -10,5 et +10 m/s, ce qui signifie que la plupart des écarts entre prévisions et observations demeurent dans cet intervalle. Enfin, l'alignement presque linéaire des points du Q-Q plot montre que les résidus suivent globalement une distribution normale, malgré de faibles écarts dans

les queues de distribution. Dans l'ensemble, les deux RNA présentent des erreurs comparables à 24 heures, mais le modèle intégrant les variables liées au mur végétalisé semble légèrement mieux contrôler le biais pour les intensités cycloniques les plus élevées.

3.3 Analyse multi-échances de la similarité, de l'incertitude et du profil des erreurs des RNA

La figure ci-dessous complète l'évaluation globale des modèles par trois dimensions complémentaires : la similarité statistique entre prévisions et observations, l'incertitude associée à la RMSE et la distribution des erreurs selon leur amplitude et la classe d'intensité cyclonique. Le diagramme de Taylor synthétise la corrélation, la variabilité et l'erreur centrée des prévisions aux différentes échéances, tandis que les intervalles bootstrap à 95 % renseignent sur la robustesse des performances. La courbe ECDF et l'analyse par classe permettent enfin d'identifier les régimes pour lesquels l'intégration des variables liées aux murs végétalisés apporte une amélioration.




Figure 3: Analyse multi-échances de la similarité, de l'incertitude et du profil des erreurs des RNA

Source : Auteur

Interprétation

Le diagramme de Taylor montre que les deux RNA reproduisent correctement la variabilité observée, avec des corrélations généralement supérieures à 0,95 et des écarts-types normalisés relativement proches de l'unité. Les performances sont meilleures aux échéances de 12 et 24 h, dont les points sont les plus proches de la référence, puis diminuent progressivement à mesure que l'horizon de prévision s'allonge. L'analyse bootstrap confirme cette évolution : la RMSE passe d'environ 4,2 m/s à 12 h à 8,4 m/s à 72 h pour le RNA sans mur, contre environ 4,1 et 9,1 m/s pour le RNA avec mur. Le modèle intégrant les variables du mur présente une RMSE légèrement plus faible à 12, 24 et 48 h, mais plus élevée à 36, 60 et 72 h. Le chevauchement important des intervalles de confiance indique toutefois que ces différences doivent être interprétées avec prudence. À 24 h, les deux courbes

ECDF sont presque confondues, ce qui traduit des distributions d'erreurs très similaires. Environ 65 % des prévisions présentent une erreur absolue inférieure à 5 m/s et près de 95 % une erreur inférieure à 10 m/s. L'analyse par classe révèle néanmoins des différences plus marquées. Le RNA avec mur réduit la MAE pour les dépressions, de près de 5,1 à 4,6 m/s, ainsi que pour les fortes tempêtes, les cyclones et les cyclones intenses, avec des diminutions approximatives de 3,9 à 3,8 m/s, de 4,3 à 3,9 m/s et de 4,5 à 4,1 m/s. En revanche, il dégrade la prévision des tempêtes modérées, dont la MAE augmente d'environ 3,9 à 5,1 m/s, et des cyclones très intenses, pour lesquels elle passe approximativement de 4,0 à 4,3 m/s. Ces résultats indiquent que l'apport des variables liées aux murs végétalisés dépend de l'échance et du régime d'intensité, avec un avantage plus net à court terme et pour certaines catégories cycloniques intermédiaires.

3.4 Evaluation catégorielle des RNA et détection des événements cycloniques

La figure suivante compare la capacité des deux configurations du RNA à prévoir les classes d'intensité cyclonique et à détecter les événements caractérisés par une vitesse maximale du vent supérieure ou égale à 33 m/s. Les matrices de confusion décrivent les performances obtenues à l'échance de 24 heures, tandis que l'accuracy, le score F1 macro et le coefficient kappa évaluent la qualité de la classification entre 12 et 72 heures. La probabilité de détection, l'indice de succès critique et le taux de fausses alarmes complètent cette analyse pour les événements cycloniques.

Evaluation catégorielle et détection d'événements




Figure 4: Evaluation catégorielle des RNA et détection des événements cycloniques

Source : Auteur

Interprétation

À 24 heures, le RNA sans mur classe correctement 77 % des dépressions, 67 % des tempêtes modérées, 66 % des fortes tempêtes, 61 % des cyclones, 68 % des cyclones intenses et 91 % des cyclones très intenses. L'intégration des variables liées au mur végétalisé améliore la reconnaissance des fortes tempêtes, des cyclones et des cyclones très intenses, dont les taux de classification correcte passent respectivement de 66 à 69 %, de 61 à 64 % et de 91 à 92 %. Cette amélioration ne concerne toutefois pas toutes les catégories. Le taux de reconnaissance des dépressions diminue de 77 à 69 %, tandis que celui des tempêtes modérées chute de 67 à 17 %, principalement en raison d'une confusion avec les dépressions et les fortes tempêtes. La classification des cyclones intenses reste pratiquement stable, avec 68 % de bonnes classifications sans mur contre 67 % avec mur. Les performances catégorielles diminuent globalement avec l'allongement de l'échéance. L'accuracy passe approximativement de 0,78 à 12 heures à 0,62 à 72 heures pour le RNA sans mur, contre environ 0,76 et 0,59 pour le RNA avec mur. À 24 heures, les deux modèles présentent une accuracy proche de 0,73, mais le RNA avec mur obtient des valeurs plus faibles de F1 macro, proches de 0,62 contre 0,70, en raison de ses difficultés à distinguer certaines classes de faible intensité. Cette dégradation devient plus nette à 60 et 72 heures, où le F1 macro du modèle avec mur se situe autour de 0,46, contre environ 0,51 à 0,54 pour le modèle de référence. La détection des événements dépassant 33 m/s demeure néanmoins élevée pour les deux RNA. La probabilité de détection varie approximativement entre 0,90 et 0,96 selon l'échéance, tandis que l'indice de succès critique reste généralement compris entre 0,86 et 0,94. Le taux de fausses alarmes demeure faible, mais augmente progressivement d'environ 0,02 à 12 heures à près de 0,08 à 72 heures. Dans l'ensemble, les variables liées aux murs végétalisés améliorent légèrement la reconnaissance de certaines intensités cycloniques élevées, mais elles ne procurent pas un avantage catégoriel systématique et peuvent accroître les confusions entre les classes voisines, notamment pour les tempêtes modérées.

4. DISCUSSION

Les résultats montrent que l'intégration de prédictors microclimatiques liés aux murs végétalisés apporte un bénéfice limité et principalement observable aux courtes échéances. À 12 et 24 h, le RNA enrichi réduit la RMSE de 2,9 % et 2,7 %, la MAE de 3,6 % et 2,5 %, ainsi que le sMAPE de 5,0 % et 3,5 %. Cette amélioration devient plus faible à 48 h, puis disparaît aux échéances longues, avec notamment une hausse de la RMSE de 8,8 % et de la MAE de 9,0 % à 72 h. Cette évolution suggère que l'information microclimatique locale peut compléter utilement les prédictors cycloniques lorsque l'horizon de prévision reste court, mais que son influence devient secondaire face à l'incertitude croissante liée à la dynamique atmosphérique et océanique. Les diagnostics des résidus confirment une bonne concordance générale entre les observations et les prévisions, avec un biais moyen proche de zéro et une majorité d'erreurs comprise entre -10 et +10 m/s. Toutefois, le chevauchement des intervalles de confiance bootstrap indique que les différences entre les deux modèles demeurent modestes. L'analyse catégorielle met également en évidence un effet contrasté. Le modèle avec mur améliore légèrement la reconnaissance de certaines classes d'intensité élevée, mais réduit le score F1 macro à 24 h, de 0,70 à 0,62, en raison de confusions accrues pour les tempêtes modérées. L'intérêt de ces variables dépend donc à la fois de l'échéance de prévision et de la classe d'intensité considérée.

5. CONCLUSION

Cette étude montre que l'intégration de prédictors microclimatiques associés aux murs végétalisés peut améliorer la prévision neuronale de l'intensité des cyclones tropicaux dans le SWIO, principalement aux courtes échéances. Les gains observés à 12 et 24 h, avec des réductions de la RMSE atteignant respectivement 2,9 % et 2,7 %, ainsi que des diminutions de la MAE de 3,6 % et 2,5 %, indiquent que ces variables peuvent apporter une information complémentaire aux prédictors cycloniques conventionnels. À 48 h, l'amélioration devient plus modérée, tandis qu'aux échéances de 60 et 72 h, l'avantage du modèle enrichi disparaît et certaines métriques se dégradent. L'analyse des résidus confirme néanmoins une bonne cohérence globale des prévisions, avec un biais moyen proche de zéro et une majorité d'erreurs comprises entre -10 et +10 m/s. Les résultats catégoriels montrent également que l'effet des variables liées aux murs végétalisés varie selon le niveau d'intensité. Le modèle enrichi améliore légèrement la reconnaissance de certaines catégories élevées, notamment les fortes tempêtes et les cyclones, mais il augmente aussi les confusions entre certaines classes voisines, en particulier pour les tempêtes modérées. Cette variabilité explique la diminution du score F1 macro à 24 h, de 0,70 pour le modèle de référence à 0,62 pour le modèle avec mur. Dans l'ensemble, les

prédicteurs microclimatiques liés aux murs végétalisés doivent être considérés comme des variables d'appoint plutôt que comme des déterminants majeurs de la prévision cyclonique. Leur apport semble surtout pertinent lorsque l'horizon de prévision est court et que les conditions locales conservent une influence mesurable sur les variables observées. Pour les échéances plus longues, la dynamique atmosphérique, l'évolution océanique et les changements internes du cyclone deviennent prédominants, réduisant l'utilité relative de l'information microclimatique. Ces résultats soulignent l'intérêt d'une sélection rigoureuse des variables et d'une utilisation différenciée selon l'échéance et la classe d'intensité. Une stratégie de modélisation adaptative pourrait ainsi privilégier les prédicteurs liés aux murs végétalisés pour les prévisions à 12 et 24 h, tout en réduisant leur poids aux horizons plus éloignés. Une telle approche permettrait de mieux exploiter leur contribution sans dégrader la stabilité générale du modèle. L'étude met ainsi en évidence le potentiel d'une intégration ciblée des informations microclimatiques dans les RNA pour renforcer la prévision à court terme de l'intensité cyclonique dans le SWIO.

REFERENCES

- [1] Malan, N., Reason, C.J.C. and Loveday, B.R. (2013) 'Variability in tropical cyclone heat potential over the Southwest Indian Ocean', *Journal of Geophysical Research: Oceans*, 118(12), pp. 6734–6746. doi: 10.1002/2013JC008958.
- [2] Mawren, D. and Reason, C.J.C. (2017) 'Variability of upper-ocean characteristics and tropical cyclones in the South West Indian Ocean', *Journal of Geophysical Research: Oceans*, 122(3), pp. 2012–2028. doi: 10.1002/2016JC012028.
- [3] DeMaria, M., Mainelli, M., Shay, L.K., Knaff, J.A. and Kaplan, J. (2005) 'Further improvements to the Statistical Hurricane Intensity Prediction Scheme (SHIPS)', *Weather and Forecasting*, 20(4), pp. 531–543. doi: 10.1175/WAF862.1.
- [4] Baik, J.-J. and Paek, J.-S. (2000) 'A neural network model for predicting typhoon intensity', *Journal of the Meteorological Society of Japan*, 78(6), pp. 857–869. doi: 10.2151/jmsj1965.78.6_857.
- [5] Xu, W., Balaguru, K., August, A., Lalo, N., Hodas, N.O., DeMaria, M. and Judi, D. (2021) 'Deep learning experiments for tropical cyclone intensity forecasts', *Weather and Forecasting*, 36(4), pp. 1453–1470. doi: 10.1175/WAF-D-20-0104.1.
- [6] Pérez, G., Coma, J., Martorell, I. and Cabeza, L.F. (2014) 'Vertical Greenery Systems (VGS) for energy saving in buildings: A review', *Renewable and Sustainable Energy Reviews*, 39, pp. 139–165. doi: 10.1016/j.rser.2014.07.055.
- [7] Wong, N.H., Tan, A.Y.K., Chen, Y., Sekar, K., Tan, P.Y., Chan, D., Chiang, K. and Wong, N.C. (2010) 'Thermal evaluation of vertical greenery systems for building walls', *Building and Environment*, 45(3), pp. 663–672. doi: 10.1016/j.buildenv.2009.08.005.
- [8] Harris, C.R., Millman, K.J., van der Walt, S.J., Gommers, R., Virtanen, P., Cournapeau, D. et al. (2020) 'Array programming with NumPy', *Nature*, 585, pp. 357–362. doi: 10.1038/s41586-020-2649-2.
- [9] McKinney, W. (2010) 'Data structures for statistical computing in Python', in van der Walt, S. and Millman, J. (eds.) *Proceedings of the 9th Python in Science Conference*. Austin, Texas, pp. 56–61. doi: 10.25080/Majors-92bf1922-00a.
- [10] Hunter, J.D. (2007) 'Matplotlib: A 2D graphics environment', *Computing in Science & Engineering*, 9(3), pp. 90–95. doi: 10.1109/MCSE.2007.55.
- [11] Virtanen, P., Gommers, R., Oliphant, T.E., Haberland, M., Reddy, T., Cournapeau, D. et al. (2020) 'SciPy 1.0: Fundamental algorithms for scientific computing in Python', *Nature Methods*, 17, pp. 261–272. doi: 10.1038/s41592-019-0686-2.
- [12] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O. et al. (2011) 'Scikit-learn: Machine learning in Python', *Journal of Machine Learning Research*, 12, pp. 2825–2830.
- [13] Kingma, D.P. and Ba, J. (2015) 'Adam: A method for stochastic optimization', *Proceedings of the 3rd International Conference on Learning Representations*. San Diego, California.
- [14] Björck, Å. (1967) 'Solving linear least squares problems by Gram-Schmidt orthogonalization', *BIT Numerical Mathematics*, 7(1), pp. 1–21. doi: 10.1007/BF01934122.

- [15] Efron, B. (1979) 'Bootstrap methods: Another look at the jackknife', The Annals of Statistics, 7(1), pp. 1–26. doi: 10.1214/aos/1176344552.