



**HAL**  
open science

# Gestion intelligente du réseau électrique réunionnais. Prévision de la ressource solaire en milieu insulaire

Hadja Maïmouna Diagne

► **To cite this version:**

Hadja Maïmouna Diagne. Gestion intelligente du réseau électrique réunionnais. Prévision de la ressource solaire en milieu insulaire. Energie électrique. Université de la Réunion, 2015. Français. NNT : 2015LARE0014 . tel-01328719

**HAL Id: tel-01328719**

**<https://theses.hal.science/tel-01328719>**

Submitted on 8 Jun 2016

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

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



**UNIVERSITE DE LA REUNION**

École doctorale Sciences, Technologies et Santé  
E.D. 542

## **THÈSE**

présentée par **Hadja Maïmouna DIAGNE**

Pour l'obtention du grade de

**Docteur**

*Spécialité : Énergétique*

### **Gestion intelligente du réseau électrique Réunionnais. Prévision de la ressource solaire en milieu insulaire**

soutenue publiquement le 28 avril 2015

#### **JURY**

Pr Richard PEREZ	Professeur, ASRC University at Albany, State of New-York	Rapporteur
Pr Philippe POGGI	Professeur, Université de Corse Pascal Paoli	Rapporteur
Dr Philippe BLANC	Ingénieur de recherche, Mines ParisTech, Sophia Antipolis	Examinateur
Pr Philippe LAURET	Professeur, Université de La Réunion	Directeur
Pr Rémy COURDIER	Professeur, Université de La Réunion	Co-directeur
Dr Mathieu DAVID	Maitre de conférence HDR, Université de La Réunion	Encadrant
Mr Nicolas SCHMUTZ	Directeur de REUNIWATT	Invité



“On ne fait pas une thèse, on entre en thèse...”.

(Ivan Lavallée)



## Remerciements

Je voudrais tout d'abord remercier les membres du jury pour m'avoir fait l'honneur d'accepter de juger ce travail de thèse :

- Richard PEREZ, Professeur, ASRC University at Albany, State of New-York
- Philippe POGGI, Professeur, Université de Corse Pascal Paoli
- Philippe BLANC, Ingénieur de recherche, Mines ParisTech, Sophia Antipolis
- Philippe LAURET, Professeur, Université de La Réunion
- Rémy COURDIER, Professeur, Université de La Réunion
- Mathieu DAVID, Maître de conférence HDR, Université de La Réunion
- Nicolas SCHMUTZ, Directeur de REUNIWATT

Je tiens à remercier en particulier mes encadrants : Philippe LAURET, Rémy COURDIER, Mathieu DAVID et Nicolas SCHMUTZ pour leurs soutiens sans faille. Les conseils prodigués au cours de ces trois années, la pertinence des critiques lors des réunions du comité de pilotages et la grande disponibilité m'ont permis d'explorer de nombreuses voies et d'étoffer considérablement mes travaux de recherche.

Je remercie également REUNIWATT pour avoir financé mes travaux de recherche et contribué à la réussite du projet sur tous les plans.

Mes remerciements vont à Ivan Lavallée pour les encouragements à faire une thèse sur un sujet qui me passionne. Merci de m'avoir soutenu dans les moments difficiles.

Je remercie John Boland pour son soutien sans faille et sa grande disponibilité.

Mes remerciements vont aussi à mes collègues et amis pour leur bonne humeur et leur soutien : Richard, Cynthia, Audrey, Émeric, Aurélie, Alain, Jean, Francois, Olivier, Frantz, Jocelyne, Alain, Gilles, Christian, Laetitia.

Enfin, mes remerciements les plus profonds vont à tous les membres de ma famille pour leurs soutiens inconditionnels.

Et à tous ceux qui étaient là, avec qui j'ai tant partagé. Merci.



# **Gestion intelligente du réseau électrique Réunionnais.**

## **Prévision de la ressource solaire en milieu insulaire**

Hadja Maïmouna DIAGNE

### **Résumé**

L'intégration de la production des énergies renouvelables intermittentes dans le mix énergétique est aujourd'hui limitée à un seuil de 30 % de la puissance totale produite. Cette mesure vise à assurer la sécurité de l'alimentation électrique des réseaux insulaires en France. La levée de ce verrou technique ne pourra se faire qu'en apportant des solutions au caractère intermittent des sources d'énergies éolienne et photovoltaïque. Les difficultés énergétiques auxquelles sont confrontés aujourd'hui les milieux insulaires préfigurent celles que rencontrera la planète à plus ou moins long terme. Ces territoires sont des laboratoires uniques pour éprouver les nouvelles technologies de stockage, de gestion et de prévision de l'énergie.

La contribution de ce travail de thèse se focalise sur la prévision du rayonnement solaire global à différents horizons de temps car la puissance photovoltaïque produite découle directement de l'intensité du rayonnement solaire global. Dans un premier temps, l'étude bibliographique a permis de classer les modèles de prévision numériques et les modèles de prévision statistiques en fonction de la résolution spatiale et temporelle. Par ailleurs, elle montre que les meilleures performances sont obtenues avec les modèles hybrides. Dans un deuxième temps, un modèle de prévisions à court terme (J+1) est proposé avec le modèle Weather Research and Forecasting (WRF) et un réseau de neurone bayésien. L'hybridation de ces deux méthodes améliore les performances de prévisions à J+1. Dans un troisième temps, un modèle de prévision à très court terme (t+h) est proposé avec le modèle hybride de Kalman. Cette méthode produit d'une part une prévision énergétique et d'autre part une prévision multi-horizon. La comparaison de la performance de ces modèles avec la méthode de référence dite de persistance montre une amélioration de la qualité de la prévision. Enfin, la combinaison du filtre de Kalman avec le modèle numérique WRF permet une mise en œuvre opérationnelle de la prévision.

**Mots clés :** prévision, réseau de neurones bayésien, modèle WRF, modèle hybride, Kalman, rayonnement global horizontal.





# **Smart operation of an electricity grid at Reunion Island.**

## **Solar irradiance forecasting in an insular context**

Hadja Maïmouna DIAGNE

### **Abstract**

The integration of intermittent renewables into the energetic mix of La Reunion island is currently limited to a threshold of 30% of the total power. This restriction aims at ensuring the grid stability and the safety of the power supply in the French insular grids . These technological issues can be resolved by providing solutions to the intermittency of wind and solar energy. Today, islands are experiencing challenges that prefigure global problems of tomorrow. These territories constitute unique small-scaled laboratories for testing new technologies of storage, management and forecasting of energy.

The contribution of this thesis focuses on the forecasting of global horizontal irradiance at different time horizons. Indeed, the generated PV power depends directly on the intensity of the global horizontal irradiance. First, a review of solar irradiance forecasting methods allows classifying numerical weather models and statistical forecasting methods according to different spatial and temporal resolutions. Moreover, it shows that better performance are obtained with hybrid models. Second, a short-term forecast (day ahead forecast) is developed using the Weather Research and Forecasting model (WRF) and a Bayesian neural network. The combination of these two methods improves the day ahead forecast accuracy. Third, a model for forecasting the very short term (from few minutes to several hours) is developed using a kalman filter with hybrid inputs. This method provides on the one hand energy forecasts and on the other hand a multi horizon solar irradiance forecast. The comparison between the developed method and the reference method, namely the persistence method, shows an improvement of the quality of the forecasts. Combining the Kalman filter with the WRF numerical model leads to an operational implementation of the forecast.

**Keywords** : forecasting, bayesian neural network, WRF model, hybrid model, Kalman, global horizontal irradiance.



# Table des matières

<b>Table des matières</b>	<b>xi</b>
<b>Table des figures</b>	<b>xv</b>
<b>Liste des tableaux</b>	<b>xix</b>
<b>Nomenclature</b>	<b>xxii</b>
<b>1 Introduction</b>	<b>1</b>
1.1 Énergies renouvelables : enjeux et défis . . . . .	1
1.2 Problématiques énergétiques en milieux insulaires . . . . .	2
1.3 Prévion du rayonnement solaire global . . . . .	4
1.4 Objectifs et démarche de la thèse . . . . .	6
1.5 Organisation du manuscrit . . . . .	8
<b>2 Review of solar irradiance forecasting methods</b>	<b>9</b>
2.1 Introduction . . . . .	11
2.2 Statistical models . . . . .	13
2.2.1 Linear models or time series models . . . . .	13
2.2.2 Non linear models . . . . .	19
2.3 Cloud imagery and satellite based models . . . . .	23
2.3.1 Cloud imagery . . . . .	24
2.3.2 Satellite Images . . . . .	25
2.3.3 Ground-based sky images . . . . .	25
2.4 Numerical weather prediction models . . . . .	25
2.4.1 NWP configuration . . . . .	26
2.4.2 Input data features . . . . .	27
2.4.3 Global model example : ECWMF . . . . .	27

2.4.4	Mesoscale models example : MM5 and WRF . . . . .	27
2.4.5	NWP model accuracy . . . . .	29
2.4.6	NWP Limitations . . . . .	30
2.4.7	Postprocessing methods . . . . .	30
2.4.8	Human interpretation of NWP output . . . . .	33
2.5	Hybrid models . . . . .	34
2.6	Future solar irradiance forecasting approaches for small-scale insular grids	34
2.7	Conclusions . . . . .	36
<b>3</b>	<b>Prévision du rayonnement global à court terme (J+1)</b>	<b>39</b>
3.1	Vue globale de la méthode proposée . . . . .	41
3.2	Modèle climatique régional WRF . . . . .	42
3.2.1	Justification du choix de WRF . . . . .	42
3.2.2	Présentation générique de WRF . . . . .	42
3.2.3	Protocole expérimental de simulation . . . . .	48
3.2.4	Analyse préliminaire du biais . . . . .	53
3.3	Modèle neuronal . . . . .	55
3.3.1	Justification du choix neuronal . . . . .	55
3.3.2	Présentation générale . . . . .	55
3.3.3	Procédure d'apprentissage . . . . .	57
3.3.4	Capacité de généralisation . . . . .	58
3.3.5	Validation simple . . . . .	59
3.3.6	Techniques de régularisation . . . . .	60
3.3.7	Régularisation bayésienne . . . . .	61
3.3.8	Mise en oeuvre du modèle neuronal . . . . .	66
3.4	Conclusion . . . . .	68
<b>4</b>	<b>Prévision du rayonnement global à très court terme (t+h)</b>	<b>69</b>
4.1	Introduction . . . . .	70
4.2	Présentation générale de la méthode . . . . .	70
4.3	Justification du modèle retenu . . . . .	72
4.4	Modèle hybride de Kalman . . . . .	73
4.4.1	Algorithme . . . . .	73
4.4.2	Initialisation des variables . . . . .	75
4.4.3	Calibration du modèle . . . . .	76
4.4.4	Identification des entrées pertinentes . . . . .	78

---

4.5	Conclusion . . . . .	86
<b>5</b>	<b>Performances des méthodes de prévision</b>	<b>87</b>
5.1	Introduction . . . . .	89
5.2	Analyse des sites . . . . .	89
5.2.1	Propriétés géographiques . . . . .	90
5.2.2	Matériel et mesures . . . . .	91
5.2.3	Contrôle de la qualité des mesures . . . . .	91
5.2.4	Classification de l'ensoleillement . . . . .	92
5.3	Performances des prévisions à court terme . . . . .	97
5.3.1	Prévisions avec le modèle de persistance . . . . .	97
5.3.2	Prévisions du modèle numérique WRF . . . . .	98
5.3.3	Post-procession des prévisions WRF avec un modèle neuronal . . . . .	102
5.3.4	Comparaison des performances de prévision . . . . .	105
5.4	Performances des prévisions à très court terme . . . . .	107
5.4.1	Prévisions énergétiques de la persistance . . . . .	107
5.4.2	Prévisions énergétiques du modèle hybride de Kalman . . . . .	108
5.4.3	Comparaison des performances de prévisions énergétiques . . . . .	110
5.4.4	Prévisions multihorizon du modèle hybride de Kalman . . . . .	112
5.5	Conclusion . . . . .	114
	<b>Conclusions et perspectives</b>	<b>115</b>
5.6	Conclusions . . . . .	115
5.7	Perspectives . . . . .	116
	<b>Bibliographie</b>	<b>117</b>
	<b>Annexe A Filtre de Kalman linéaire</b>	<b>125</b>
A.1	Modèle espace-état . . . . .	125
A.2	Filtre de Kalman . . . . .	126
	<b>Annexe B Publications</b>	<b>129</b>
B.1	Publications en revue internationale . . . . .	129
B.2	Publications en conférence internationale . . . . .	129



# Table des figures

1.1	Évolution annuelle de la puissance PV installée et du tarif d'achat . . . . .	3
1.2	Vue globale de la démarche . . . . .	7
2.1	Sketch of a MLP with $d$ inputs and $h$ hidden units [50] . . . . .	20
2.2	Topology of wavelet neural network. Extracted from Gaige[91]. . . . .	22
2.3	Input data to WRF model [86]. . . . .	28
2.4	Classification of model based on spatial and temporal resolution . . . . .	35
2.5	Relation between horizons, models and activities . . . . .	35
3.1	Vue globale de la démarche J+1 . . . . .	41
3.2	Séquencement temporel de la démarche J+1 . . . . .	41
3.3	Organigramme du cœur dynamique ARW de WRF [92]. . . . .	43
3.4	Étapes de la préparation des données [92]. . . . .	44
3.5	Coordonnées verticales en niveaux $\sigma$ [86]. . . . .	46
3.6	Grille Arakawa C. . . . .	47
3.7	Position des domaines imbriqués dans l'Océan Indien. . . . .	49
3.8	Résolution horizontale des trois domaines imbriqués . . . . .	50
3.9	Comparaison des prévisions WRF à l'horizon t+24h aux mesures réelles. . . . .	54
3.10	Variation du biais prévisionnel $k_t^*$ en fonction de $\cos(\text{SZA})$ . . . . .	54
3.11	Neurone formel . . . . .	56
3.12	Perceptron Multicouche . . . . .	56
3.13	Validation simple . . . . .	59
3.14	Évolution de l'erreur en fonction du nombre de neurones cachés . . . . .	60
3.15	Entrées et sorties du modèle neuronal. . . . .	67
4.1	Vue globale de la démarche de prévision à l'horizon t+h . . . . .	70
4.2	Horizons du modèle hybride de prévision énergétique . . . . .	71
4.3	Principe de fonctionnement du modèle de prévision multihorizon. . . . .	72



4.4	Entrées et sortie du modèle hybride de Kalman . . . . .	73
4.5	Algorithme de la méthode hybride. . . . .	75
4.6	Évolution des erreurs en fonction de $Q_0$ et $R_0$ . . . . .	76
4.7	Variation du RMSE avec ou sans fenêtre glissante. . . . .	77
4.8	Trace de la matrice de covariance $B_t$ avec $Q_0$ et $R_0$ . . . . .	78
4.9	Moyenne spatiale du GHI des pixels contigus au site . . . . .	79
4.10	Synthèse de la prévision du biais avec le modèle de Pelland. . . . .	80
4.11	Variation du RMSE relatif en fonction de l'ordre des entrées. . . . .	81
4.12	Variation du RMSE relatif en fonction de la variable supplémentaire. . . . .	82
4.13	Prévision du biais de l'indice de ciel clair du modèle WRF à l'horizon de 1h. . . . .	84
4.14	RMSE relatif en fonction des entrées . . . . .	85
5.1	Stations météorologiques. . . . .	89
5.2	CMP11 Kipp & Zonen . . . . .	91
5.3	Rayonnement Global à Saint-Pierre en 2011 et 2012 avec ou sans SERI-QC. . . . .	93
5.4	Distribution des mesures par rapport à la qualité de l'ensoleillement. . . . .	94
5.5	Classification des mesures par rapport aux classes de l'indice de ciel clair. . . . .	95
5.6	Exemple d'ensoleillement de chaque classe . . . . .	95
5.7	Classification de l'ensoleillement. . . . .	96
5.8	Classification des mesures par rapport aux critères. . . . .	96
5.9	Prévisions du modèle persistance à t+24h . . . . .	97
5.10	Prévisions du modèle WRF à t+24h. . . . .	98
5.11	Variation mensuelle des indices de ciel clair. . . . .	99
5.12	Variation mensuelle du MBE et du RMSE relatif avec le modèle WRF. . . . .	100
5.13	Variation du biais previsionnel $k_t^*$ en fonction de $\cos(\text{SZA})$ . . . . .	101
5.14	Exemple de prévisions de chaque type de jour à l'horizon t+24h. . . . .	101
5.15	Prévisions du modèle WRF à t+24h. . . . .	102
5.16	Comparaison des Indices de ciel clair mensuels prévus et réels. . . . .	103
5.17	Variation mensuelle du MBE et du RMSE avec le modèle neuronal. . . . .	103
5.18	Variation du biais de WRF en fonction de $\cos(\text{SZA})$ et $k_t^*$ . . . . .	104
5.19	Exemple de prévisions du lendemain de chaque type de jour. . . . .	105
5.20	Variation du MBE relatif pour chaque classe d'ensoleillement. . . . .	106
5.21	Variation du RMSE relatif pour chaque classe d'ensoleillement. . . . .	107
5.22	Comparaison des prévisions h+1 (1 heure en avance) de la persistance et du modèle hybride de Kalman avec les mesures au sol. . . . .	108

---

5.23	Entrées et Sortie du modèle hybride de Kalman. . . . .	108
5.24	Variation mensuelle du MBE et du RMSE du modèle hybride énergétique. .	109
5.25	Erreurs de prévision en fonction de la position du soleil. . . . .	109
5.26	Variation du MBE en fonction de l'horizon de prévision énergétique. . . . .	110
5.27	Variation du RMSE en fonction de l'horizon de prévision énergétique. . . . .	110
5.28	Exemple de prévisions énergétiques de chaque type de jour à l'horizon t+1h.	111
5.29	Variation du MBE en fonction de l'horizon de prévision du modèle hybride multihorizon. . . . .	112
5.30	Variation du RMSE en fonction de l'horizon de prévision. . . . .	113
5.31	Exemple de prévisions multihorizon de chaque type de jour à l'horizon t+1h.	113
A.1	Algorithme du filtre de Kalman [77] . . . . .	128



# Liste des tableaux

1.1	Actions du gestionnaire de réseau électrique. . . . .	5
4.1	Notation des variables d'entrées testées. . . . .	79
4.2	Performances de prévision en fonction des entrées à l'horizon de 1h. . . . .	86
5.1	Propriétés des sites étudiés. . . . .	90
5.2	Test qualité et taux de données rejetées. . . . .	92
5.3	Répartition en % des mesures par rapport à la qualité de l'ensoleillement. . . . .	93
5.4	Répartition en % des mesures par rapport à la variabilité. . . . .	94
5.5	Classification des mesures de Saint-Pierre et du Tampon. . . . .	96
5.6	Synthèse des RMSE et MBE de chaque site pour l'horizon t+24h. . . . .	107
5.7	Synthèse des RMSE et MBE de chaque site pour l'horizon t+1h. . . . .	112
5.8	Synthèse des RMSE et MBE de chaque site pour l'horizon t+1h. . . . .	114



# Nomenclature

## Abbréviations

$\widehat{GHI}_{wrf t+1}$	Prévision du rayonnement global obtenu avec le modèle WRF
$\beta$	Hyperparamètre représentatif de l'écart type de l'erreur
$\mu$	Coefficient de régularisation ou hyperparamètre
$E_D$	Fonction de coût des moindres carrés classique
$E_T$	Fonction de coût à minimiser
$E_w$	Fonction de pénalité
$Z_D$	Facteur de normalisation du bruit blanc gaussien
$Z_F$	Facteur de normalisation
$Z_w$	Constante de normalisation de la fonction de densité de probabilité

## Acronymes

ARW	Advanced Research WRF
GHI	Global Horizontal Irradiance ou rayonnement global horizontal
MLP	Multilayer perceptron ou Perceptron multicouche
NCAR	National Center for Atmospheric Research
NCEP	National Centers for Environmental Prediction
NCL	NCAR Command Language
NMM	Non-Hydrostatic Meso-scale Model
RNA	Réseaux de neurones artificiels

WPS	WRF Preprocessing System
WRF	Weather Research and Forecasting

# Chapitre 1

## Introduction

### 1.1 Énergies renouvelables : enjeux et défis

Les enjeux énergétiques deviennent essentiels dans un monde où la croissance démographique et économique tire à la hausse les besoins énergétiques et où les émissions de gaz à effet de serre induites par ces besoins sans cesse accrus conduisent au changement climatique de la planète. L'agence internationale de l'énergie annonce un accroissement de la demande mondiale en énergie primaire de 45 % et de celui de la demande d'électricité de 80 %, entre 2006 et 2030 [40]. Le Groupe d'experts intergouvernemental sur l'évolution du climat (GIEC) indique que 85 % de l'énergie primaire, moteur de l'économie mondiale, provient de la combustion de ressources fossiles, et que la consommation de ces combustibles représente 56,6 % des émissions de gaz à effet de serre (GES). Cette augmentation des émissions de GES liée à la prestation de services énergétiques est la cause majeure du réchauffement climatique [26]. La croissance des besoins soulève la question de la sécurité d'approvisionnement, le changement climatique celle de la durabilité du système énergétique, l'ensemble devant être appréhendé en tenant compte des enjeux économiques et notamment de compétitivité que les choix énergétiques impactent directement.

Un changement majeur dans la manière de produire et de consommer l'énergie est nécessaire pour maintenir à la fois une économie durable, capable de fournir des biens et des services essentiels à la population et un système climatique mondial favorable. La Commission Européenne a adopté une série de mesures visant à réduire les émissions de gaz à effet de serre de 20 %, à utiliser les énergies provenant de sources renouvelables à hauteur de 20 % et à augmenter de 20 % l'efficacité énergétique pour l'horizon 2020.

Dans le nouveau scénario énergétique, les combustibles fossiles vont céder de plus en plus la place aux énergies renouvelables. Cette transition implique des changements im-



portants dans l'organisation, la structuration et la gestion, à tous les niveaux, des systèmes d'approvisionnement en électricité. Le solaire et l'éolien, sources d'énergie renouvelables abondantes et disposant de technologies matures pour les transformer en électricité, sont potentiellement intéressants pour la production de l'électricité dans le futur. Le principal inconvénient de ces sources d'énergie renouvelables dites intermittentes est leur forte variabilité dans le temps et dans l'espace. Les énergies renouvelables intermittentes, à savoir celles issues de la conversion du rayonnement solaire ou de la vitesse du vent, présentent des caractéristiques de production fondamentalement différentes de celles produites à partir de sources d'énergie conventionnelles (par exemple, les combustibles fossiles). Alors que la production d'énergie à partir de sources conventionnelles peut facilement être adaptée à la demande d'électricité, la disponibilité des énergies renouvelables intermittentes est largement déterminée par les conditions météorologiques. Cette intermittence représente un défi majeur à leur intégration dans le réseau électrique et nécessite l'introduction de nouvelles méthodes pour équilibrer l'offre et la demande.

La problématique de l'intégration de la production des énergies renouvelables intermittentes dans le mix énergétique est encore plus sensible dans les régions insulaires.

## 1.2 Problématiques énergétiques en milieux insulaires

Dans le domaine de l'énergie, les milieux insulaires présentent la particularité de former des systèmes isolés ne bénéficiant pas, ou très peu, d'interconnexions à un réseau électrique continental. L'électricité doit être produite sur place et l'équilibre offre-demande est fragile. Le contexte des territoires insulaires français allié à une politique d'incitation avec un tarif d'achat élevé, notamment du photovoltaïque entre 2005 et 2009 [81], a favorisé le développement des énergies photovoltaïques et éoliennes ainsi que des productions décentralisées. Or, à la différence des énergies renouvelables à puissance contrôlable, l'éolien et le photovoltaïque sont respectivement soumis aux variations du vent et de l'ensoleillement et donc de la météorologie locale. Le caractère intermittent qui en résulte crée, pour leur insertion dans un réseau insulaire, des difficultés techniques encore plus contraignantes que pour les grands réseaux interconnectés : les systèmes électriques insulaires sont en effet plus fragiles et « instables » que les systèmes continentaux.

La loi du 3 août 2009 issue du Grenelle de l'environnement [52] a été mise en place dans l'objectif de promouvoir le développement des énergies renouvelables dans les territoires d'outre mer. Elle ambitionne, dès 2020, de produire 50 % de la consommation d'énergie à partir des énergies renouvelables. Dans ce contexte, les énergies renouvelables

se développent fortement. La Figure 1.1 illustre l'évolution exponentielle de la puissance photovoltaïque installée à La Réunion [75]. Ainsi, en février 2012, 152 MW de panneaux photovoltaïques étaient raccordés aux réseaux contre 9.9 MW en 2008.

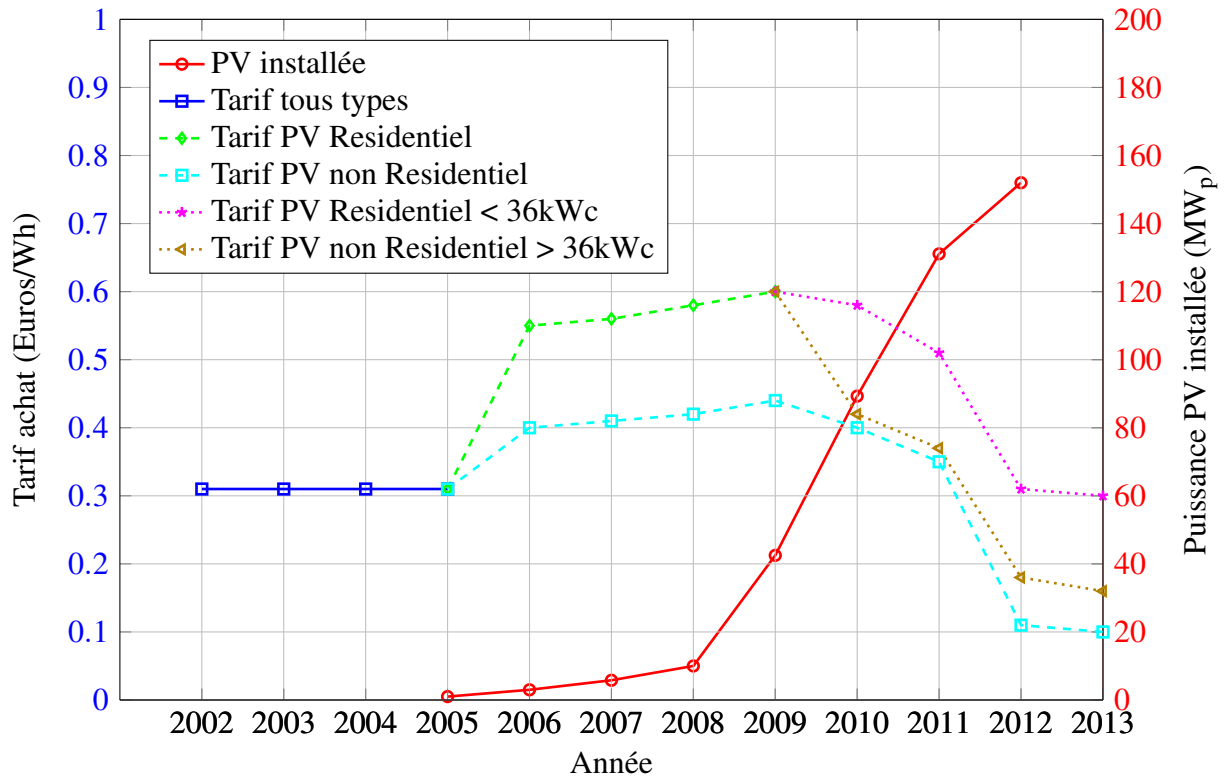


FIGURE 1.1 Évolution annuelle de la puissance PV installée et du tarif d'achat à La Réunion.

La politique tarifaire incitative [81], illustrée par la Figure 1.1, a généré une croissance exponentielle de la puissance photovoltaïque installée entre 2005 et 2009. Cette forte croissance pouvant mettre à mal l'équilibre du réseau, les autorités ont voté l'arrêté ministériel du 24 novembre 2010 [1]. Celui-ci fixe le seuil maximal d'énergies intermittentes à 30 % de la puissance appelée sur le réseau. Au delà de ce seuil, le gestionnaire de réseau est autorisé à déconnecter des sources de production intermittentes. La Réunion atteint cette limite de 30 % les jours ensoleillés, venteux et/ou fériés [90]. Cette mesure vise à assurer la sécurité de l'alimentation électrique des réseaux insulaires en France.

La levée de ce verrou technique ne pourra se faire qu'en apportant des solutions au caractère intermittent des sources d'énergies éolienne et photovoltaïque, ces dernières pouvant alors occuper une plus grande place dans le mix énergétique.

### **Comment favoriser l'intégration des énergies renouvelables au sein du Mix énergétiques ? Comment débloquer le verrou technique du seuil de 30 % ? Comment pallier l'intermittence des sources d'énergies renouvelables ?**

Aujourd'hui, le problème d'intermittence est traité principalement en adaptant la charge des centrales électriques conventionnelles, notamment celles dites à flammes qui sont souples, afin de compenser les fluctuations dans la production d'énergie renouvelable. Le recours à ces solutions palliatives, le plus souvent fortement émettrices de CO<sub>2</sub> ou de particules fines, va à l'encontre des objectifs de diminution des impacts environnementaux. Une maîtrise de la consommation d'énergie à travers le déplacement des charges électriques des périodes de pointe vers les périodes creuses où l'énergie est disponible et bon marché est un concept actuellement étudié du côté de la maîtrise de la demande énergétique. Elle contribuera à établir une meilleure adéquation entre la demande et la fourniture d'énergies renouvelables. Les technologies de stockage et de foisonnement des sources de production sont également appelées à jouer un rôle important dans la réduction de l'écart entre la demande d'électricité et la production d'énergie renouvelable.

Tous ces concepts ont besoin d'informations détaillées sur les prévisions de la production et de la consommation d'énergie qui représentent un élément essentiel pour les stratégies de gestion et d'exploitation du réseau électrique. Par conséquent, des prévisions fiables des productions d'énergies renouvelables intermittentes sont importantes pour une intégration efficace de quantités importantes d'énergies renouvelables dans le mix énergétique. Notre contribution se focalise sur la prévision du rayonnement solaire global à différents horizons de temps car la prévision photovoltaïque découle directement de celle du rayonnement solaire global.

## **1.3 Prévision du rayonnement solaire global**

Les prévisions, ou estimations de l'évolution à court, moyen ou long terme d'une variable ou d'un phénomène, servent de base à la prise de décisions et à l'élaboration de stratégies. Toutefois, elles n'ont de valeur que si elles sont adaptées à l'application visée. Les méthodes de prévision doivent être élaborées de concert entre les utilisateurs et les analystes afin de définir le contexte et les objectifs de leur application.

Dans le cadre de la participation des énergies renouvelables intermittentes au mix énergétique, le gestionnaire du réseau électrique a besoin de prévisions sur la production pour assurer un système d'approvisionnement électrique sécurisé et économique. Ces besoins en terme d'horizon de prévision et de granularité sont synthétisés dans le tableau 1.1. Les

actions qu'ils permettront de réaliser, se présentent ainsi [89] :

- Les **prévisions immédiates** : elles ont un horizon de prévision allant de 15 minutes à 2 heures avec une granularité de 30 secondes à 5 minutes. Ces prévisions offrent la possibilité de prendre des décisions liées à la Régulation (réglage) et à la distribution en temps réel ;
- Les **prévisions à très court terme** : elles ont un horizon de prévision allant de 1 heure à 6 heures avec une granularité horaire. Elles sont utilisées dans le suivi des charges (« load following ») et dans l'actualisation du planning d'utilisation des moyens de production ;
- Les **prévisions à court terme** : elles ont un horizon de prévision allant de 1 jour à 3 jours avec une granularité horaire. Elles sont exploitées dans le choix des unités de production («Unit commitment») de manière à minimiser les coûts liés aux temps de redémarrage et d'arrêt des unités. En outre, elles aident à optimiser la planification des moyens de production, de stockage et de maîtrise de la demande énergétique.

Prévisions	Horizons	Granularités	Actions
Immédiates	15 mn à 2 h	30 s à 5 mn	Régulation, distribution à temps réel.
Très court terme	1 h à 6 h	1 h	Suivi des charges, actualisation du planning.
Court terme	1 à 3 jours	1 h	Unit commitment, planning.

TABLE 1.1 Actions du gestionnaire de réseau électrique.

Aujourd'hui, dans les pays où la production éolienne est importante, la prévision occupe une part essentielle dans les systèmes de contrôle des réseaux électriques ([72], [11]). Par analogie, la prévision de la production photovoltaïque est de plus en plus importante, surtout dans les pays où la législation incite au déploiement de l'énergie solaire. L'intérêt des prévisions de production photovoltaïque repose sur leurs précisions. Par conséquent, des efforts croissants sont actuellement consacrés à la recherche pour améliorer les prévisions du rayonnement solaire et par conséquent les prévisions de puissance photovoltaïque correspondante.

Des prévisions du rayonnement solaire fiables permettront d'apporter des solutions au caractère intermittent de l'énergie photovoltaïque et ainsi ouvrir la porte à une plus grande

part de cette énergie au sein des réseaux électriques.

Les difficultés énergétiques auxquelles sont confrontées aujourd'hui les milieux insulaires préfigurent celles que rencontreront la planète à plus ou moins long terme. Ces territoires sont des laboratoires uniques pour éprouver les nouvelles technologies de stockage, de gestion et de prévision de l'énergie. Cela s'explique par leurs spécificités énergétiques, à savoir un gisement important d'énergies renouvelables, un bouquet énergétique majoritairement fossile, un accès à l'énergie complexe et coûteux et un réseau intrinsèquement plus fragile et plus sensible. Dans ce contexte, nous avons développé des méthodes de prévisions avec des horizons allant de quelques minutes à un jour pour répondre aux besoins des gestionnaires de réseaux électriques et des producteurs photovoltaïques.

## 1.4 Objectifs et démarche de la thèse

L'objectif principal de cette thèse est d'améliorer la prévision du rayonnement global horizontal (GHI) en milieu insulaire en vue d'anticiper les intermittences de la production photovoltaïque. Pour cela, nous avons développé des méthodes de prévision avec des horizons définis en fonction des échelles temporelles des moyens techniques palliatifs de l'intermittence de la production photovoltaïque.

Une étude bibliographique a permis de mettre en évidence les différentes méthodes de prévision du GHI actuellement utilisées et leurs horizons de performances. La nécessité de faire des prévisions à l'horizon J+1 avec une granularité horaire justifie le choix des modèles atmosphériques (NWP) largement utilisés à travers le monde par les services météorologiques. Cependant, à cause de leur faible résolution spatiale et temporelle, les modèles NWP globaux ne sont pas adaptés pour prévoir les phénomènes micro-climatiques existant dans les territoires de petite taille. Pour prendre en compte ces phénomènes micro-climatiques, il est nécessaire de procéder à une descente d'échelle de la résolution spatiale et temporelle avec un modèle numérique régional ou méso-échelle. Notre choix de modèle numérique régional s'est porté sur le Weather Research and Forecasting (WRF). Il a l'avantage d'être libre, facile à utiliser et les données d'initialisation sont simples à acquérir. En outre, le développement du modèle WRF s'appuie sur une communauté scientifique large et dynamique.

Les prévisions de rayonnement solaire faites avec les modèles numériques pour l'horizon J+1 sont connues pour présenter un fort biais [57]. Ceci est dû aux difficultés liées aux performances insuffisantes des modèles de transfert radiatifs lors des situations partiellement nuageuses. Les nuages étant reproduits de manière moyennée sur chacun des pixels,

ces modèles ne peuvent pas résoudre un ciel partiellement couvert. Il est alors nécessaire de les affiner avec une méthode de post-traitement. Les méthodes de post-traitement développées pour les milieux continentaux telles que le moyennage spatial (ou spatial averaging) ne sont pas forcément adaptées aux milieux insulaires. En effet, le GHI est une série temporelle sujette à de fortes variations spatio-temporelles en milieu insulaire en raison du nombre élevé de microclimats. D'autre part, une analyse du biais produit par le modèle WRF (voir section 3.2.4) a mis en évidence des relations non linéaires liant le biais à des variables explicatives. Dans ce contexte, le réseau de neurones artificiel, outil statistique ayant la capacité d'apprendre des relations non linéaires complexes à partir des données disponibles [7], a été retenu pour faire le post traitement des prévisions numériques à court terme. La Figure 1.2 illustre la démarche globale suivie dans cette thèse.

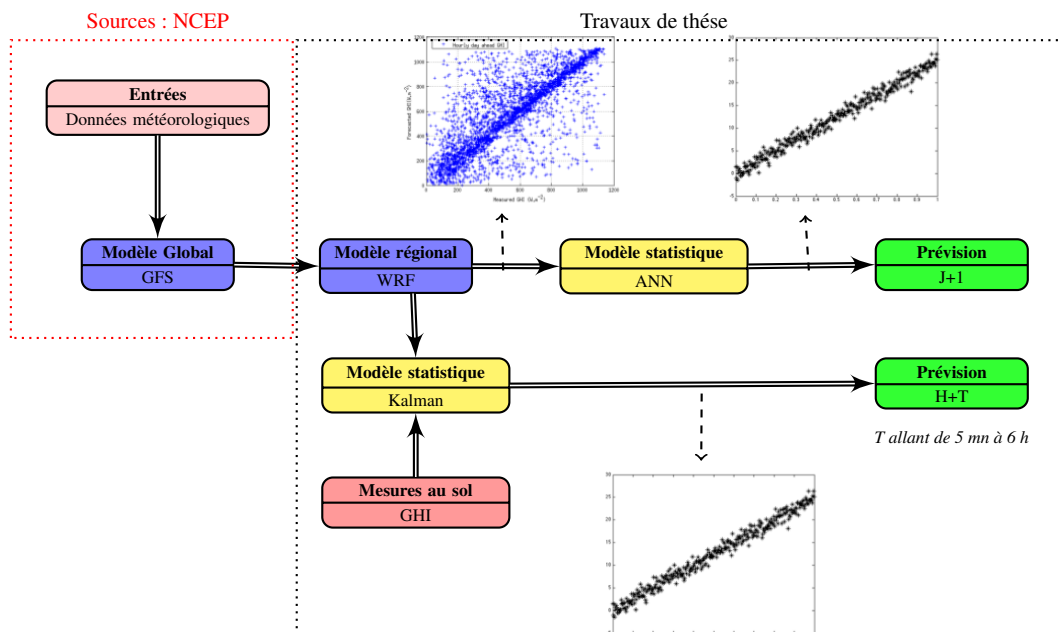


FIGURE 1.2 Vue globale de la démarche

Les besoins de prévisions à court et très court terme des gestionnaires, résumés dans le tableau 1.1, nous ont amené à nous intéresser aux modèles statistiques. L'étude bibliographique a soulevé la limite des méthodes statistiques endogènes qui utilisent uniquement des mesures historiques. Par conséquent, nous avons procédé à des tests de combinaisons d'entrées dans un modèle statistique récursif. Cette étude a conduit à la proposition d'un modèle hybride de Kalman avec une entrée endogène et une entrée exogène provenant du modèle numérique méso-échelle.

Les deux méthodes de prévision proposées, à court et très court terme, ont fait l'objet

d'une étude comparative avec des méthodes identifiées dans l'étude bibliographique. Deux sites situés à l'île de La Réunion sont utilisés, chacun disposant de microclimats différents et d'une importante base de données de mesures pyranométriques du rayonnement solaire.

## 1.5 Organisation du manuscrit

Le présent rapport de thèse est structuré en cinq chapitres.

Le **chapitre 2** présente l'état de l'art des méthodes de prévision. Les notions fondamentales du rayonnement solaire ainsi que les modèles de référence sont abordés. Une classification des modèles de prévision suivant les caractéristiques des données d'entrées est identifiée. L'étude bibliographique a permis de déterminer les domaines de performance suivant la résolution spatiale et temporelle et l'horizon de prévision. Le chapitre 2 a été publié dans le journal de rang A *Renewable and Sustainable Energy Reviews* [22].

Le **chapitre 3** traite de la prévision à court terme (J+1) du rayonnement solaire global. La première étape est dédiée à l'optimisation du modèle numérique WRF en terme de performance de calcul dans un environnement distribué et fortement parallélisé. Le modèle WRF a été configuré en tenant compte des spécificités du milieu insulaire pour produire des prévisions du GHI. La dernière partie apporte de l'intelligence artificielle par l'intermédiaire d'un réseau de neurones bayésien. L'erreur systématique identifiée dans les prévisions faites par le modèle numérique est corrigée par le réseau de neurones bayésien.

Le **chapitre 4** propose une méthode de prévision hybride à très court terme allant de 5 minutes à 3 heures. La méthode statistique de Kalman combinée aux prévisions du modèle numérique WRF est appliquée. La conception du modèle hybride a été réalisée avec une année de données GHI. La phase de validation a également été faite avec une année de données GHI.

Le **chapitre 5** présente les performances des méthodes proposées dans cette thèse. Elles sont comparées aux performances des méthodes existantes. Deux sites avec des propriétés géographiques et micro-climatiques différentes sont utilisés.

En dernier lieu, le **chapitre 6** présente les conclusions de nos travaux, en évoquant les possibilités de perspectives.

# Chapitre 2

## Review of solar irradiance forecasting methods and a proposition for small-scale insular grids

Ce chapitre a été publié dans la revue internationale de rang A Renewable and Sustainable Energy Reviews [22]. Il présente les résultats de l'étude bibliographique faite sur les méthodes de prévision du rayonnement solaire existantes. Cette étude a pour objectif de faciliter le choix de la méthode de prévision en fonction des besoins de l'utilisateur. Trois grandes familles de méthodes de prévision sont identifiées à savoir les méthodes statistiques, les méthodes numériques et les méthodes hybrides. Ensuite, une classification de ces méthodes en fonction de la résolution spatiale et de la résolution temporelle est faite. Enfin, une méthode de prévision est proposée pour les réseaux insulaires non-connectés.

### Sommaire

---

<b>2.1</b>	<b>Introduction</b>	<b>11</b>
<b>2.2</b>	<b>Statistical models</b>	<b>13</b>
2.2.1	Linear models or time series models	13
2.2.1.1	Persistence forecast	14
2.2.1.2	Preprocessing of input data	14
2.2.1.3	ARMA model	16
2.2.1.4	ARIMA techniques	17
2.2.1.5	CARDS model	18
2.2.2	Non linear models	19
2.2.2.1	Artificial Neural Network (ANN)	19



2.2.2.2	Wavelet Neural Network . . . . .	21
2.2.2.3	ANN and classical time series models comparison . . . . .	23
<b>2.3</b>	<b>Cloud imagery and satellite based models . . . . .</b>	<b>23</b>
2.3.1	Cloud imagery . . . . .	24
2.3.2	Satellite Images . . . . .	25
2.3.3	Ground-based sky images . . . . .	25
<b>2.4</b>	<b>Numerical weather prediction models . . . . .</b>	<b>25</b>
2.4.1	NWP configuration . . . . .	26
2.4.1.1	Temporal resolution . . . . .	26
2.4.1.2	Spatial resolution . . . . .	26
2.4.2	Input data features . . . . .	27
2.4.3	Global model example : ECWMF . . . . .	27
2.4.4	Mesoscale models example : MM5 and WRF . . . . .	27
2.4.4.1	Input data . . . . .	28
2.4.4.2	Grid Nesting . . . . .	29
2.4.4.3	MM5 and WRF configuration . . . . .	29
2.4.5	NWP model accuracy . . . . .	29
2.4.6	NWP Limitations . . . . .	30
2.4.7	Postprocessing methods . . . . .	30
2.4.7.1	Model output statistics (MOS) . . . . .	31
2.4.7.2	Kalman filter . . . . .	32
2.4.7.3	Temporal interpolation . . . . .	32
2.4.7.4	Spatial averaging . . . . .	32
2.4.7.5	Physical postprocessing approaches . . . . .	33
2.4.8	Human interpretation of NWP output . . . . .	33
<b>2.5</b>	<b>Hybrid models . . . . .</b>	<b>34</b>
<b>2.6</b>	<b>Future solar irradiance forecasting approaches for small-scale insu- lar grids . . . . .</b>	<b>34</b>
<b>2.7</b>	<b>Conclusions . . . . .</b>	<b>36</b>

---

## Abstract

Integration of solar energy into the electricity network is becoming essential because of its continually increasing growth in usage. An efficient use of the fluctuating energy output of photovoltaic (PV) systems requires reliable forecast information. In fact, this integration can offer a better quality of service if the solar irradiance variation can be predicted with great accuracy.

This paper presents an in-depth review of the current methods used to forecast solar irradiance in order to facilitate selection of the appropriate forecast method according to needs. The study starts with a presentation of statistical approaches and techniques based on cloud images. Next numerical weather prediction or NWP models are detailed before discussing hybrid models. Finally, we give indications for future solar irradiance forecasting approaches dedicated to the management of small-scale insular grids. Le chapitre 2 a été publié dans la revue *Renewable Energy review* [22].

## 2.1 Introduction

The contribution of photovoltaic systems (PV system) power production to the electric power supply is constantly increasing. Utility companies and transmission system operators have to deal with the fluctuating input from PV system energy sources. This is a new challenge compared with power production from conventional power plants that can be adjusted to the expected load profiles. An efficient use of the fluctuating energy output of PV systems requires reliable forecast information.

Note that the reliable forecasting of the expected solar resource is but one aspect of the broad question of solar resource assessment that ranges from, for example the work of Perez and al [79] on variability to Lucia [61] on the link between the entropy generation maximum principle and the exergy analysis of engineering and natural systems. In this paper, we focus solely on the, once again, broad field of forecasting, broad both in approaches taken, and the time scales covered.

Load patterns forecasted for the next 2 days provide the basis for scheduling of power plants and planning transactions in the electricity market in order to balance the supply and demand of energy and to assure reliable grid operation [54]. These forecasts are used by utility companies, transmission system operators, energy service providers, energy traders, and independent power producers in their scheduling, dispatching and regulation of power.

In particular, insular territories experience an unstable electricity network and use ex-

pensive means in order to provide the power for the peak demand periods. Their grids are generally not interconnected with any continent and all the electricity must be produced inside the territory. The power of grid connected PV plants increases fast and can interfere with network stability. An efficient forecasting method will help the grid operators to better manage the electrical balance between demand and power generation. Kostylev and Pavlovski [89] identify three forecasting horizons (intra-hour, intra-day and day ahead) related to the grid operator activities (ramping events, variability related to operations, unit commitment, transmission scheduling, day ahead markets, hedging, planning and asset optimization).

Forecasting of global horizontal irradiance (GHI) is the first and most essential step in most PV power prediction systems. GHI forecasting approaches may be categorized according to the input data used which also determine the forecast horizon.

- Statistical models based on online irradiance measurements are applied for the very short term timescale from 5 minutes up to 6 hours (see Reikard, [82]). Examples of direct time series models are autoregressive (AR) and autoregressive moving average (ARMA) models. Furthermore, artificial neural networks (ANN) may be applied to derive irradiance forecasts.
- For short-term irradiance forecasting, information on the temporal development of clouds, which largely determine surface solar irradiance, may be used as a basis.
  - Forecasts based on cloud motion vectors from satellite images (Lorenz and al, [53]) show good performance for the temporal range from 30 minutes up to 6 hours.
  - For the subhour range, cloud information from ground-based sky images may be used to derive irradiance forecasts with much higher spatial and temporal resolution compared with the satellite-based forecasts.
- For longer forecast horizons, from about 4–6 hours onward, forecasts based on numerical weather prediction (NWP) models typically outperform the satellite-based forecasts (see Perez and al[79], Heinemann and al.[31]).
- There are also combined approaches that integrate different kinds of input data to derive an optimized forecast depending on the forecast horizon.

Solar irradiance forecasts was assessed in terms of root mean square error (RMSE) and mean bias error (MBE or bias) which are defined as follows :

$$RMSE = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (x_{pred,i} - x_{obs,i})^2} \quad (2.1)$$

$$MBE = \frac{1}{n} \cdot \sum_{i=1}^n (x_{pred,i} - x_{obs,i}) \quad (2.2)$$

where  $x_{pred,i}$  and  $x_{obs,i}$  represent the  $i^{th}$  valid forecast and observation pair, respectively and  $n$  is the number of evaluated data pairs. These metrics are not formulated in the same way in all the papers we reviewed. David and al [21] illustrated several formula wrongly called RMSE or MBE.

Many solar irradiance forecasting models have been developed. These models can be divided into two main groups : statistical models and NWP models. Statistical models are based upon the analysis of historical data. They include time series models, satellite data based models, sky images based models, ANN models, wavelet analysis based models, etc. NWP models are based on the reproduction of physical phenomenon.

The paper is organized as follow. In Section 2, statistical approaches are presented. In Section 3, cloud imagery and satellite based models proposed in the literature are reviewed. In Section 4, the NWP approaches presented in the literature are reviewed. In Section 5, hybrid models are evaluated. Finally Section 6 is dedicated to trends for future solar irradiance forecasting in an insular environment.

## 2.2 Statistical models

Forecasting methods based on historical data of solar irradiance are two categories : statistical and learning methods. Seasonality analysis, Box-Jenkins or Auto Regressive Integrated Moving Average (ARIMA), Multiple Regressions and Exponential Smoothing are examples of statistical methods, whilst AI paradigms include fuzzy inference systems, genetic algorithm, neural networks, machine learning etc.

### 2.2.1 Linear models or time series models

Statistical methods have been used successfully in time series forecasting for several decades. Using the statistical approach, relations between predictors, variables used as an input to the statistical model, and the variable to be predicted, are derived from statistical analysis. Several studies with respect to direct time series modeling have been performed. In Reikard [82], different time series models are compared. In Bacher and al.[2], the authors investigate the use of a simpler AR model to directly predict PV power in comparison with other models.

### 2.2.1.1 Persistence forecast

It is useful to check whether the forecast model provides better results than any trivial reference model. It is worthwhile to implement and run a complex forecasting tool only if it is able to clearly outperform trivial models. Probably the most common reference model in the solar or wind forecasting community for short term forecasting is the persistence model. The persistence model supposes that global irradiance at time  $t + 1$  is best predicted by its value at time  $t$  :

$$\hat{X}_{t+1} = X_t$$

The persistence forecast, also known as the naïve predictor, can be used to benchmark other methods. Persistence forecast accuracy decreases strongly with forecast duration as cloudiness changes from the current state. Generally, persistence is an inaccurate method for more than 1 hour ahead forecasting and should be used only as a baseline forecast for comparison to more advanced techniques.

In Perez and al.[79], the single site performance of the forecast models is evaluated by comparing it to persistence.

### 2.2.1.2 Preprocessing of input data

When using statistical time series analysis, any type of conditional forecast model is structured to deal with stationary series, at least weakly stationary. This means no trend nor seasonality, and the series is homoscedastic (constant variance). There are several ways to deal with non-stationary series to get them into an appropriate form.

**Processes to obtain stationary solar irradiance time series** The solar insolation is the actual amount of solar radiation incident upon a unit horizontal surface over a specified period of time for a given locality. It depends strongly on the solar zenith angle. For statistical models, it may be favorable to treat the influences of the deterministic solar geometry and the non-deterministic atmospheric extinction separately. For this purpose, two transmissivity measures have been introduced : clearness index ( $k$ ) and clear-sky index ( $k^*$ ).

**Clearness index** The clearness index  $k$  is defined as the ratio of irradiance at ground level  $I$  to extraterrestrial irradiance  $I_{ext}$  on an horizontal plane :

$$k = I/I_{ext} \tag{2.3}$$

It describes the overall extinction by clouds and atmospheric constituents in relation to the extraterrestrial irradiance. This approach strongly reduces seasonal and daily patterns by considering the influence of the zenith angle, which is modeled by  $I_{ext}$ . The clearness index is widely applied to reduce the deterministic trend in irradiance time series. However, the clearness index accounts for only the trends caused by geometric effects on solar position. As atmospheric extinction depends on the length of the path of the radiation through the atmosphere, it is also governed by solar geometry [54].

**Clear sky index** The clear-sky index decreases with increasing of solar zenith angle. To account for this influence as well, the clear-sky index  $k^*$  is introduced.  $k^*$  is defined as the ratio irradiance at ground level  $I$  to irradiance of a defined clear-sky model  $I_{clear}$  :

$$k^* = I/I_{clear} \quad (2.4)$$

For the calculation of the clear-sky index, a clear-sky model and information on atmospheric input parameters are required. A clear sky model estimates the global irradiance, usually referred to as clear-sky irradiance  $I_{clear}$ , in clear sky conditions at any given time. An overview of different models is presented by Ineichen [41]. Clear-sky models range from empirical models to radiative transfer-based calculations. All these models need information on the state of the atmosphere as input [54].

The quantities introduced in this section are frequently used in solar modeling and forecasting. For example, some time series models explicitly require input parameters free of trend ; hence, clearness index or clear-sky index can be an adequate choice. Also, satellite-based forecasts of irradiance are based on the concept of separately describing the influence of clouds and other atmospheric components by using the clear-sky index and a clear-sky model. Furthermore, most empirical models to derive the diffuse fraction of irradiance, necessary to calculate the irradiance on a tilted plane, are generally based on the clearness or clear-sky index.

Preprocessing of the input data can considerably contribute to improving the accuracy of forecasts, and different approaches are proposed. As mentioned earlier, stationary, trend-free time series are required for classical time series approaches, and might be beneficial also for ANN. Hence, the use of the clear-sky or clearness index instead of irradiance data seems suitable. This approach is followed, for example, in Bacher and al.[2], and Kemmoku and al. [47]. On the other hand, Sfetsos and Coonick [85] argues that time series of the clearness or clear-sky index are mostly random, and hence do not provide a good basis for any learning algorithm. They recommend using irradiance values as input. Other examples

of preprocessing of input data are the use of wavelets in Cao [14] and the use of the logarithm of irradiance values in Reikard [82].

**Statistical tools for removing trend and seasonality** Because of its unpredictable noise, it is not easy to find the trend in a day's series of solar irradiance. Several models exist to detrend the hourly solar irradiance (Baig and al.[4], Kaplanis [46]). Clear sky index, as described above, is one model to obtain the deterministic daily variation of irradiance. Fourier series is also a good predictor of the cyclical dependence of solar radiation, combining several significant frequencies in its depiction. Boland [9, 10] has shown that it captures yearly and intra-day cycles and can be used to effectively model the daily profile of solar irradiance time series, as well as capturing the variation over the year.

To judge the goodness of different detrending models, Ji and Chee [43] use the Augmented Dickey–Fuller (ADF) test to measure the stationarity of the detrended series. ADF is a test for unit root in a time series.

A time series possesses a unit root if it is a realization of the process

$$X_t = \alpha X_{t-1} + Z_t \quad (2.5)$$

where  $\alpha = 1$  and  $Z_t \sim WN(0, \sigma_Z^2)$ . *WN* indicates white noise, that is independent and identically distributed.

If there is a unit root in a time series, it is not stationary ; There are other conditions for stationarity as well, for instance  $\alpha$  cannot be greater than unity, but if all conditions hold then the time series may be considered stationary.

### 2.2.1.3 ARMA model

The ARMA model is based on two elementary models : the moving average model (MA) and the autoregressive model (AR) as :

$$S(t) = \sum_{i=1}^p \alpha_i S(t-i) + \sum_{j=1}^q \beta_j e(t-j) \quad (2.6)$$

In equation (2.6),  $S(t)$  is the forecasted solar irradiance at time  $t$ . In the AR model,  $p$  is the order of the AR process, and  $\alpha_i$  is the  $i$ th AR coefficient. In the MA model,  $q$  is the order of the MA error term,  $\beta_j$  is the  $j$ th MA coefficient and  $e(t)$  is the white noise that are uncorrelated random variables with zero mean and constant variance [13].

The Autoregressive Moving Average (ARMA) model is usually applied to auto correlated time series data. This model is a great tool for understanding and predicting the future value of a specified time series. ARMA is based on two parts : autoregressive (AR) part and moving average (MA) part. Also, this model is usually referred to as ARMA (p, q). In this p and q are the order of AR and MA respectively. The popularity of the ARMA model is its ability to extract useful statistical properties and the adoption of the well-known Box–Jenkins methodology (see Boland [10]). ARMA models are very flexible since they can represent several different types of time series by using different order. It has been proved to be competent in prediction when there is an underlying linear correlation structure lying in the time series. One major requirement for ARMA model is that the time series must be stationary (see Hamilton [30]).

#### 2.2.1.4 ARIMA techniques

An extension of the ARMA models, the Auto-Regressive Integrated Moving Average (ARIMA) time series models form a general class of linear models that are widely used in modelling and forecasting time series in (see Box and Jenkins [13]). The ARIMA(p,d,q) model of the time series  $\{X_1, X_2, \dots\}$  is defined as

$$\Phi_p(B)\Delta^d X_t = \Theta_q(B)a_t \quad (2.7)$$

where

$$\Phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (2.8)$$

$$\Theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q. \quad (2.9)$$

B is the backward shift operator,  $BX_y = X_{y-1}$ ,  $\Delta = 1 - B$  is the backward difference, and  $\Phi_p$  and  $\Theta_q$  are polynomials of order p and q, respectively. ARIMA(p,d,q) models are the product of an autoregressive part AR(p) (equation 2.8), an integrating part  $I(d) = \Delta^{-d}$ , and a moving average MA(q) part (equation 2.9). The parameters in  $\Phi$  and  $\Theta$  are chosen so that the zeros of both polynomials lie outside the unit circle in order to avoid generating unbounded processes.

For some random shocks (being events such that the time series value departs from the time series average) drawn from a fixed distribution with mean zero and variance  $\sigma_a$ , a sequence  $a_t, a_{t-1}, a_{t-2} \dots$ , is called the white noise process. The backshift operator and the white noise process describe the intrinsic features of the time series : adjacent observations



are dependent.  $a_t$  is an independent shock of time step  $t$  of the white noise process.

The ARIMA (Auto–Regressive Integrated Moving Average) techniques (see Hamilton [30]) are reference estimators in the prediction of global irradiance field. It is a stochastic process coupling autoregressive component (AR) to a moving average component (MA), after differencing at appropriate time steps to remove any trends. It is in this way that ARIMA models allow treatment of non-stationary series.

Reikard [82] applies a regression in log to the inputs of the ARIMA models to predict the solar irradiance. He compares ARIMA models with other forecast methods such as ANN. At the 24-h horizon, he states that the ARIMA model captures the sharp transitions in irradiance associated with the diurnal cycle more accurately than other methods.

### 2.2.1.5 CARDS model

Jing et al [39] have developed a coupled autoregressive (AR) and dynamical system model to forecast solar radiation time series on hourly and intra-hourly time scales.

The equation of the dynamical system part, the Lucheroni model is :

$$\dot{R} = z \quad (2.10)$$

$$\varepsilon \dot{z} = \kappa(z + R) - \lambda(3R^2z + R^3) - \varepsilon z - \gamma R - b + \zeta \quad (2.11)$$

where  $\kappa, \lambda, \varepsilon, \gamma$  and  $b$  are adjustable parameters, and  $\zeta$  is the noise term.

In the equation 2.10,  $\dot{R}$  denotes the derivative of  $R$  with respect to time, and hence  $z$  stands for the second derivative of  $R$  with respect to time.

The following discretised version of the model for our deseasoned solar radiation time series  $R_t$  is used :

$$R_{t+1} = R_t + z_t \Delta_t + \omega_t \quad (2.12)$$

$$z_{t+1} = z_t + [\kappa(z_t + R_t) - \lambda(3R_t^2 z_t + R_t^3) - \varepsilon z_t - \gamma R_t - b] \cdot \frac{\Delta_t}{\varepsilon} + a_t \quad (2.13)$$

$\omega_t$  and  $a_t$  are noise terms,  $\Delta_t$  is the time step. The parameters  $\kappa, \lambda, \varepsilon, \gamma$  and  $b$  can be estimated using the method of ordinary least squares (OLS).

The deseasoning was performed using Fourier series techniques as in Boland [9, 10]. The residual series formed by subtracting the Fourier series component from the original series cannot be modeled sufficiently using an autoregressive process alone. This is because the autoregressive process is too efficient at mean reversion to be able to reach the peaks

in the series. The introduction of a resonating model introduced for the power market by Lucheroni [60] plus the judicious intermittent use of a proxy for curvature allows for a much superior fit to this residual series. The results found for the CARDS model compare very favourably with what Kostylev and Pavlovski [89] found from their survey of the literature. From that paper, the best performing model at the 1 h time step had a rRMSE of 17% for mostly clear days and 32% for mostly cloudy, whereas for the CARDS model it is 16.5% for all days.

## 2.2.2 Non linear models

For about one decade, there has been great interest in research on artificial intelligence (AI) techniques, not only for forecasting but also for a broad range of applications, including control, data compression, optimization, pattern recognition, and classification. An overview of the application of AI techniques for modeling and forecasting of the solar irradiance is presented in Mellit and Kalogirou,[67] where several approaches have been compared and analyzed.

### 2.2.2.1 Artificial Neural Network (ANN)

As an alternative to conventional approaches, ANNs have been successfully applied for solar irradiance estimation.

The most popular form of neural network is the so called multilayer perceptron (MLP) structure (see Lauret [50]). The MLP structure consists of an input layer, one or several hidden layers and an output layer. The input layer gathers the model's inputs vector  $x$  while the output layer yields the model's output vector  $y$ . Figure 2.1 represents a one hidden layer MLP.

The hidden layer is characterized by several non-linear units (or neurons). The non-linear function (also called activation function) is usually the tangent hyperbolic function  $f(x)$ .

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.14)$$

Therefore, a neural network with  $d$  inputs,  $h$  hidden neurons and a single linear output unit defines a non-linear parameterized mapping from an input  $x$  to an output  $y$  given by the




FIGURE 2.1 Sketch of a MLP with  $d$  inputs and  $h$  hidden units [50]

following relationship :

$$y = y(x; w) = \sum_{j=0}^h [w_j f(\sum_{i=0}^d w_{ji} \cdot x_i)] \quad (2.15)$$

The parameters of the NN model are given by the so called weights and biases that connect the layers between them (notice that in Eq. 2.15, the biases are denoted by the subscripts  $i = 0$  and  $j = 0$  and are not represented in Fig. 2.1). The NN parameters, denoted by the parameter vector  $w$ , govern the non-linear mapping.

ANNs recognize patterns in data and have been applied to solar forecasting. Using training data, ANNs reduce normalized root mean square error (rRMSE) of daily average GHI by as much as 15% when compared to 12–18 hour ahead NWP forecasts (see Guarnieri and al.[28]).

Heinemann and al. [31] use satellite images for horizons below 6 h ; In Lorenz and al., [56] longer horizons of forecast produces by NWP models are used as input to an ANN to predict global irradiance.

Mellit and Pavan [68] developed a Multilayer Perceptron MLP-model to forecast the solar irradiance 24 hours ahead. The proposed model accepts as input parameters mean daily irradiance and mean daily air temperature ; The output is solar irradiance data 24 hours ahead. Performance prediction of a grid-connected PV plant at Trieste, Italy, had a correlation coefficient of more than 98% for sunny days and slightly less than 95% for

cloudy days.

Kemmoku and al, [47] used a multistage ANN to predict GHI of the next day. The input data to the network are the average atmospheric pressure, predicted by another ANN and various weather data of the previous day. Irradiance forecast by the multi-stage and the single-stage neural networks are compared with measured irradiance. The results show that the mean bias error (MBE) reduces from about 30% (by the single-stage) to about 20% (by the multi-stage).

Sfetsos and Coonick [85] use ANN to make one-step predictions of hourly values of global irradiance and to compare them with linear time series models that work by predicting the clearness index. They introduced an approach for forecasting hourly solar irradiance using various artificial intelligence based techniques (ANN and ANFIS). They also investigated other meteorological variables such as temperature, wind speed, and pressure. A comparison between the various models in terms of prediction error and training time indicated that the network trained with the Levenberg–Marquardt algorithm (LM) network was as the optimum prediction model.

Mihalakakou and al., [69] developed a total solar irradiance time series simulation model based on ANN and applied it in Athens. The Neural Logic Network was identified as the model with the least error. It incorporates Logic Rules that produced an rRMSE of 4.9% lower than the persistence approach.

Fatih and al., [33] developed a time delay neural network (TDNN) model from general feed forward neural network to obtain the relationship between the input and output position in time series. Conventional ANN provides their response to the weighted sum of the current inputs. For TDNN, it extends the sum to a finite number of past inputs. In this way, the output provided by a given layer depends on the output of the previous layer's computed values based on the temporal domain of input values. Because of the very similar structure of the TDNN and the general MLP, back-propagation with some modifications can be applied to train the TDNN. The strength of this algorithm is its ability to model nonlinear series. With TDNN, there is no need to specify a particular model form, since the model is adaptively formed based on the features presented by the data. This data driven algorithm is suitable for many time series where no theoretical model is available.

#### 2.2.2.2 Wavelet Neural Network

Wavelet transform has time-frequency localization property and focal features and neural network (NN) has self-adaptive, fault tolerance, robustness, and strong inference ability. How can one combine the advantages of wavelet transform and NN to solve practical prob-

lems ? The so-called wavelet neural network (WNN) or wavelet network (WN) is a variety of two techniques and inherits the advantages of the neural network and wavelet transformation. WNN uses the wavelet function as the activation function instead of the Sigmoid or tangent hyperbolic activation function. For WNN, the transfer function of hidden layer nodes is the mother wavelet function ; and the network signal is prior to transmission while error is backpropagation in the training process. The network topology is shown in Figure 2.2.




FIGURE 2.2 Topology of wavelet neural network. Extracted from Gaige[91].

In Figure 2.2,  $x_1, x_2, \dots, x_n$  is the input vector ;  $y_1, y_2, \dots, y_n$  is the predicted output ; and  $w_{ij}$  and  $w_{kj}$  are the weights connecting every layer and  $h_j$  is mother wavelet function.

For the input signal sequence  $x = (x_1, x_2, \dots, x_n)$  , the output of the hidden layer is calculated as

$$h(j) = h_j \left[ \frac{\sum_{i=1}^n \omega_{ij} x(i) - b_j}{a_j} \right], j = 1, 2, \dots, m, \quad (2.16)$$

where  $h(j)$  is output value for the node  $j$  in the hidden layer ;  $h_j$  is the mother wavelet function ;  $w_{ij}$  is weight connecting the input layer and hidden layer ;  $b_j$  is the shift factor, and  $a_j$  is the stretch factor for  $h_j$ .

The output of the output layer is calculated as

$$y(k) = \sum_{i=1}^m \omega_{ik} h(i), k = 1, 2, \dots, l, \quad (2.17)$$

where  $h(i)$  is the output value for node  $i$  in the hidden layer;  $w_{ik}$  is weight connecting the hidden layer and output layer;  $l$  and  $m$  are the number of nodes for output layer and the hidden layer, respectively.

Mellit and al.[66] proposed an adaptive wavelet-network model for forecasting daily total solar irradiance. In this study, several structures have been investigated for resolving the missing data problem. In this particular estimation process, the model consists of an adaptive neural-network topology with the wavelet transformation embedded in the hidden units.

Cao and Lin, [15] proposed a new model for forecasting global solar irradiance based on diagonal recurrent wavelet neural network (DRWNN) and a special designed training algorithm. Simulation examples proved that the model is capable of mapping solar irradiance that is usually highly non-linear and time-changeable. This is because the DRWNN combines the advantages of both RNN (recurrent neural network) and wavelet neural network (WNN).

### 2.2.2.3 ANN and classical time series models comparison

A comparison of ANN and classical time series models has been carried out in Reikard [82] and in Sfetsos and Coonick [85]. Both studies find that the error of a simple regression model can be reduced considerably by a factor in the range of 0.6 – 0.8 when using advanced models. Reikard [82] compares a regression model, the UCM Model, an ARIMA, a transfer function model, a neural network model and hybrid model. For this study, the author uses a logarithmic scaling of the input. Results show that for the resolutions of 60, 30 and 15 minutes, the ARIMA model shows better results. In Sfetsos and Coonick [85], a feed-forward ANN is identified as the most appropriate. The analysis in Reikard [82] for several stations with different climatic conditions also shows that there is a strong influence of the climatic conditions on both forecast accuracy and potential for improvement by the use of advanced models.

## 2.3 Cloud imagery and satellite based models

The method from estimated solar radiation from satellite images is complex, involving several steps. For full details, please see Lorenz [54] and Rigollier [83].

### 2.3.1 Cloud imagery

Besides the deterministic daily and annual patterns of irradiance, clouds cover as well as cloud optical depth have the strongest influence on solar irradiance at surface level. Clouds show a strong variability in time and space. Hence, determination of clouds at a designated time is an essential task in irradiance forecasting and modeling. For forecast horizons up to some hours, the temporal change of cloud structures is strongly influenced by cloud motion as a result of horizontal advection.

Satellites and ground-based sky images, have been used for the determination and forecasting of local solar irradiance conditions. The basis of this method relies upon the determination of the cloud structures during the previous recorded time steps. Extrapolation of their motion leads to a forecast of cloud positions and, as a consequence, to the local radiation situation. Satellites and ground-based sky images with their high temporal and spatial resolution offer the potential to derive the required information on cloud motion.

Through processing of satellite or ground images, clouds can be detected, characterized, and advected to predict GHI relatively accurately up to 6 hours in advance. The time series models based on satellite data and sky images detect the motion of cloud structures using motion vector fields (see Lorenz and al. [53]).

Irradiance for all sky conditions including cloudy skies may be derived using radiative transfer models (RTM) (see Heinemann and al. [31]) requiring input on the vertical structure of cloud physical parameters, for example, cloud and ice water content or droplet radius. Numerical weather prediction (NWP) models (see section 2.4) imply parameterizations of radiative transfer calculations.

The errors of satellite data and sky images based forecasts proposed in the literature increase drastically under low sun elevations, high spatial variabilities and low irradiance conditions. Hammer and al. [29] demonstrated achieved 17% rRMSE in satellite imagery for 30 minutes cloud index forecasts and 30% rRMSE at 2 h forecast horizons. For intra-day forecasts, a reduction in rRMSE by 7–10% compared to persistence forecasts was found.

Chow and al [19] presented a technique for intra-hour, sub-kilometer cloud shadow now-casting and forecasting using a ground-based sky images for selected days at the UC San Diego. This technique allows one to obtain sky cover, cloud motion, cloud shadows, irradiance, and to forecast cloud locations.

### 2.3.2 Satellite Images

An approach to forecast solar irradiance based on Meteosat satellite images as a basis for PV power forecast was proposed in Lorenz and al. [57]. They investigated and compared various methods to derive motion vector fields from Meteosat data, and applied them to forecast solar irradiance up to some hours ahead. In Perez and al. [79], the results of irradiance forecasts based on the images of the Geostationary Operational Environmental Satellite (GOES) with a similar approach patterned after Lorenz and al, [53] are shown.

### 2.3.3 Ground-based sky images

To achieve high temporal and spatial resolution for intra-hour forecasts, NWP and satellite forecasts are currently inadequate. Ground observations using a total sky imager (TSI) present an opportunity to fill this forecasting gap and deliver a sub-kilometer view of cloud shadows over a large-scale PV power plant or an urban distribution feeder.

Compared with satellite data, ground-based sky images offer a much higher spatial and temporal resolution, including the possibility of capturing sudden changes in the irradiance, often referred to as ramps, on a temporal scale of less than 1 minute. The maximum possible forecast horizon strongly depends on the cloud speed and is limited by the time until the monitored cloud scene has passed the location or area of interest. This time is determined by the spatial extension of the monitored cloud scenes in combination with cloud velocities. In Chow and al [19], forecasts up to 5 minutes ahead were evaluated for 4 partly cloudy days. An estimation of a maximum possible extension of the forecast horizon in dependence on the cloud scene resulted in values ranging from 5 to 25 minutes.

Only short deterministic forecast horizons are feasible using a single TSI at a site due to low clouds and large clouds variabilities at the fine spatial scale studied. Capturing these features deterministically is nearly impossible with satellite or NWP approaches (Chow and al [19]).

## 2.4 Numerical weather prediction models

Numerical weather prediction (NWP) models are operationally used to forecast the state of the atmosphere up to 15 days ahead. The temporal development of the state of the atmosphere is modeled by the basic differential equations that describe the physical laws governing the weather [54].



Starting from initial conditions that are derived from worldwide observations, in a first step, the future state of the atmosphere is calculated with a global NWP model. Global NWP models are currently in operation at about 15 weather services. Examples are the Global Forecast System (GFS) run by the US National Oceanic and Atmospheric Administration (NOAA) and the European Centre for Medium-Range Weather Forecasts (ECMWF). Global models usually have a coarse resolution and do not allow for a detailed mapping of small-scale features, although resolution has increased rapidly during the last few years and nowadays, depending on the model, is in the range of 16 – 50 km. In the next step, different concepts may be applied to account for local effects and to derive improved site-specific forecasts. One possibility is the downscaling by mesoscale models, which are also referred to as regional models. Mesoscale models cover only a part of the Earth but can be operated with a higher spatial resolution. They are routinely run by national weather services and private weather companies. Also, postprocessing methods, may be applied to model local effects. They allow the correction of systematic deviations in dependence on different meteorological parameters and for modeling of the irradiance if it is not provided as output parameter of an NWP model. In the next few subsections we will review NWP configuration, input data feature, global model example, mesoscale model example, NWP accuracy, NWP limitation and postprocessing methods.

## **2.4.1 NWP configuration**

Before running an NWP model, it should be configured. The principal variables to fix are the time step of internal calculation and the horizontal resolution of grid points.

### **2.4.1.1 Temporal resolution**

The internal time step gives the period over which the change of the atmospheric variables is described by the dynamic equations. Temporal resolution of internal calculations in NWP models usually is considerably higher than that of the output variables. Output variables are delivered with a resolution of typically 1 hour for regional models and 3 – 6 hours for global models. This internal time step may be down to 30 seconds for highly resolved calculations with mesoscale models and is about 10 minutes for global NWP models.

### **2.4.1.2 Spatial resolution**

The horizontal resolution determines the spatial extent of weather phenomena that can be directly simulated. Grid points are usually distributed equally in the horizontal range. The

resolution of global NWP models nowadays is in the range of 16 – 50 km. In mesoscale models, the horizontal resolution may be down to 1 km ; weather services typically operate mesoscale models with a spatial resolution in the range of 5 – 20 km. The resolution of vertical levels is generally adapted to the occurrence of physical processes that take place in certain regions of the atmosphere.

### **2.4.2 Input data features**

To start a forecast, information on the current state of the atmosphere is necessary. For global NWP models, this information is obtained from a worldwide network of meteorological observations and measurements. The key variables needed are the three-dimensional fields of wind, temperature, and humidity and the two-dimensional field of surface pressure. Boundary variables like snow cover or sea surface temperature are also of high importance. Regional models use initial conditions as well as lateral boundary conditions from global NWP model output, and also offer the possibility of integrating local measurements.

### **2.4.3 Global model example : ECWMF**

ECMWF provides weather forecasts up to 15 days ahead, including solar surface irradiance and different cloud parameters as model output. ECMWF forecasts have shown their high quality as a basis for both wind and solar power forecasts. These forecasts are described here as an example of global NWP model forecasts.

The evaluations of ECMWF-based irradiance in Lorenz and al. [57], [59],[55] are based on the T799 version with a spatial resolution of 25 km x 25 km. The current version T1279 was implemented in January 2010 and shows a horizontal resolution of 16 km x 16 km. Ninety-one hybrid vertical levels resolve the atmosphere up to 0.01 hPa corresponding to approximately 80 km. The temporal resolution of the forecasts is 3 h for the first 3 forecast days that are most relevant for PV power prediction.

### **2.4.4 Mesoscale models example : MM5 and WRF**

The non-hydrostatic, fifth-generation mesoscale model MM5 has been developed at Pennsylvania State University and subsequently at the National Center for Atmospheric Research (NCAR). It uses a terrain-following coordinate, solves its finite-difference equations with a time-split scheme, and has multiple nesting capabilities (Grell and al. [27]. The WRF model is designed to be a flexible, state-of-the-art model and is developed as

a collaborative effort of several institutes. WRF is supported as a community model with continuous development and integrates features of different mesoscale models, including also MM5 and the Eta model of the National Centers for Environmental Prediction (NCEP). In this sense, WRF can be seen as a follow-up model to MM5. The current WRF model, version 3, is described in Skamarock and al. [86]. Both WRF and MM5 offer a number of parameterizations for the different physical processes. This allows adapting the configuration of the model to the specific climatic conditions for an interested region. In addition, the capability of MM5 and WRF to integrate local measurements, for example, aerosols, may also contribute to improving forecast accuracy. The simulation of mesoscale and small-scale phenomena, which is essential for calculations with high spatial resolution, is supported by the non-hydrostatic dynamics. With the possibility of high spatial resolution, the effects of topography may be considered in much more detail than for large-scale models.

#### 2.4.4.1 Input data

Mesoscale models require input from global NWP models for initialization and boundary conditions. Frequently, GFS data of NOAA are used to initialize MM5 or WRF for operational applications, because, in contrast to ECMWF data, they are available for free. The input data used have a significant influence on the results, especially for cloudy conditions. This has been demonstrated in a case study reported in Heinemann and al. [31], where different NWP models (ECMWF and the global and local models of the German Weather Service (DWD)) were compared for initialization. Figure 2.3 illustrates patterns of input data for regional NWP model.

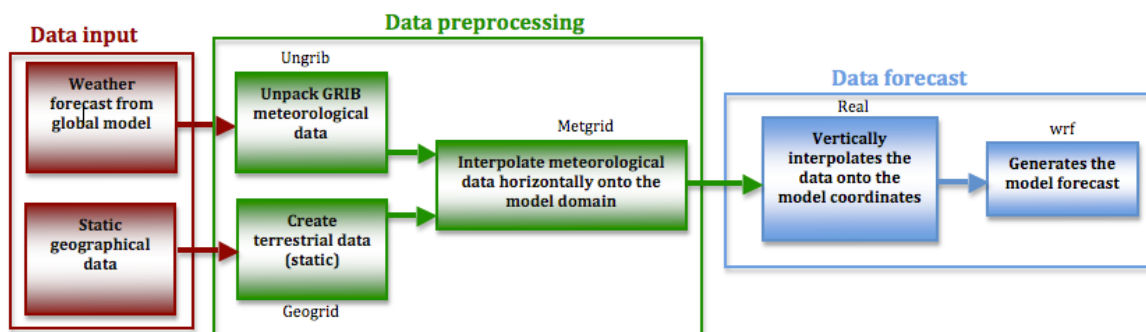


FIGURE 2.3 Input data to WRF model [86].

#### 2.4.4.2 Grid Nesting

To achieve the intended high spatial resolution in a mesoscale model with reasonable computing time, the resolution of the driving global model is increased stepwise with internal nesting. For example, in the study reported in Heinemann and al. [31], the outer domain of MM5 covering large parts of Europe has a resolution of 27 km x 27 km, the next domain has a resolution of 9 km x 9 km, and the final resolution of the innermost domain is 3 km x 3 km.

#### 2.4.4.3 MM5 and WRF configuration

Recently, several research groups have investigated the potential of MM5 and WRF irradiance forecasts for solar energy applications. In a first step, an appropriate setup of MM5 or WRF has to be determined. Heinemann and al. [31] has addressed this task by comparing different configurations of the cumulus, moisture, and planetary boundary layer parameterizations with respect to irradiance calculations in a case study. To limit the computational effort when rerunning simulations for several configurations, a set of 6 test days was defined covering different cloud conditions : clear sky, broken clouds, and overcast.

Heinemann and al. [31], show an evaluation of MM5 forecasts for a 40-day period in summer 2003 in Southern Germany in comparison with other forecasting approaches. Two studies comparing different methods to predict solar irradiance including WRF forecasts for different locations in the United States are reported in Remund and al. [42] and in Perez and al. [78]. In Lara-Fanego and al. [49], a detailed evaluation study of WRF irradiance forecasts in Andalusia (Southern Spain) is given with calculations of 1 month for each season.

#### 2.4.5 NWP model accuracy

Forecasts beyond 6 hours, up to several days ahead, are generally most accurate if derived from NWP models. NWP models predict GHI using columnar (1D) radiative transfer models (RTM) (see Heinemann and al., [31]). Heinemann and al. [31] showed that the MM5 mesoscale model can predict GHI in clear skies without bias. However, the bias was highly dependent on cloud conditions and becomes strong in overcast conditions.

Perez and al. [80] examined the accuracy of the National Digital Forecast Database (NDFD), a derivative of the operational NWP models published by the NCEP. After a local correction function was applied, results show that for 8–26 h forecast horizons, the NDFD had an hourly-average GHI relative RMSE (rRMSE) of 38%.

Remund and al. [42] evaluated different NWP-based GHI forecasts in USA, reporting rRMSE values ranging from 20% to 40% for a 24 h forecast horizon. Similar results were reported by Perez and al. [79], evaluating NWP-based irradiance forecasts in several places in the USA. Remund and al. [42] examined NWP biases compared to a single site and find that ECMWF and GFS next day GHI forecasts have a Mean Bias Error (MBE) of 19%. This MBE was found to be approximately constant for intra-day (hour-ahead) to 3 days ahead forecast horizons.

Lorenz and al. [58] evaluated several NWP-based GHI forecasts in Europe. Overall, results showed rRMSE values of about 40% for Central Europe and about 30% for Spain. Evaluating ECMWF accuracy in Germany, Lorenz and al. [57] showed that NWP MBE was largest for cloudy conditions with moderate clear sky index ( $0.3 < kt^* < 0.6$ ), while forecasted clear conditions were relatively unbiased. They reported rRMSE values of about 35% for single stations for a 24 h horizon forecasts.

#### 2.4.6 NWP Limitations

A limitation of NWP forecasting is its coarse resolution. Even the  $0.1^\circ \times 0.1^\circ$  NAM spatial resolution is insufficient to resolve most clouds. Only an average cloud cover can be forecasted for a given point. For global models (GFS and ECMWF) the resolution is even coarser. However, even if the spatial resolution is finer, the temporal output intervals would not permit the assessment of time dependent cloud cover variability, important in predicting ramp rates and ranges of variability for solar power plants. Although NWP model time-steps are on the order of minutes, the RTM are run less frequently, and the output is only hourly (NAM) or every 3 h (GFS and ECMWF). Consequently, any patterns with characteristic time scales less than an hour are unresolved. Linking observed temporal variability in GHI to native NWP forecasts will require further research.

#### 2.4.7 Postprocessing methods

Postprocessing methods are frequently applied to refine the output of NWP models like presented in Lorenz [54]. In particular, they may be utilized to :

- reduce systematic forecast errors (correction of systematic deviations);
- account for local effects (e.g., topography);
- derive parameters that are not directly provided by the NWP models (e.g., solar surface irradiance is still not a standard output parameter);
- combine the output of different models in an optimum way.

Various approaches have been proposed to address these issues, some of which are presented in the following subsections.

#### 2.4.7.1 Model output statistics (MOS)

MOS relates observed weather elements to appropriate variables (predictors) via a statistical approach. These predictors may be NWP model forecast, prior observations, or geoclimatic data.

A state-of-the-art MOS for solar irradiance predictions based on ECMWF forecasts has been introduced in Bofinger and Heilscher [8]. Multiple regression is applied to modify long-term monthly mean values of the forecasted data. Direct model output of ECMWF and statistically derived predictors are used to create daily solar electricity predictions accurate to 24.5% rRMSE for averaged daily forecasts. The MOS is operated on the basis of ground-measured irradiance values when available. For locations without irradiance measurements, irradiance derived from Meteosat data with the Heliosat method is used instead. A comparison of irradiance forecasts using this MOS scheme with WRF forecasts and other approaches is given in Heinemann and al. [31] and Lorenz and al. [57].

Lorenz and al. [57] related forecasted solar zenith angle (SZA) and clear sky index to ECMWF MBE for Germany, revealing a consistent over-prediction (up to  $100W.m^{-2}$ ) for moderately cloudy conditions. Using a MOS correction function eliminated bias and reduced RMSE of hourly forecasts by 5% for 24 h forecasts. A stepwise multivariate fourth-order regression was applied to derive the MOS correction function. In Mathiesen and Kleissl [64] the analysis and MOS correction of GHI forecasts from NAM, GFS, and ECMWF models within the continental United States was presented. They indicated that MOS application to the NWP irradiance output was successful in minimizing bias and reducing RMSE, but did not provide information about bias source. MOS corrections in the measured clear sky regime did not reduce RMSE. This is because the MOS could not distinguish between RTM errors (over-prediction of GHI even for clear skies, especially for NAM) and cloud model errors (incorrect parameterization of RTM inputs). Consequently, many initially accurate forecasts were unnecessarily corrected. Differentiating between the sources of the error is important to selectively correct forecasts. Although traditionally MOS schemes are mostly based on linear regression, any statistical approach relating observed variables to NWP output fits to the concept of MOS. In particular, ANN have also been used to improve NWP output with respect to irradiance prediction (Cao and Lin[16], Guarneri and al.[28]). In Guarneri and al.[28], an ANN is applied to irradiance forecasts of the NCEP Eta model run operationally at the Brazilian Center for Weather Forecasts and Climate Studies

(CPTEC/INPE). An evaluation with measurements for two stations in the south of Brazil reveals a strong overestimation of the irradiance by the original forecasts, and a considerable improvement is achieved by the application of an ANN using different atmospheric forecast parameters of the Eta model as input.

#### **2.4.7.2 Kalman filter**

Systematic deviations of NWP output variables often depend on the meteorological situation. In Lorenz and al. [57], a bias correction in dependence on the predicted cloud situation for the application to ECMWF irradiance forecasts is introduced. A method for bias removal of irradiance forecasts using Kalman filtering is introduced and compared with the bias correction according to Lorenz and al. [57]. Kalman filters are designed to efficiently extract a signal from noisy data and are therefore expected to show a more robust performance if only limited training data are available, which is the case if the training is performed on the basis of individual stations.

Pelland et al. [77] found that the most suitable realization of their approach was a set of Kalman filter equations established separately for each forecast horizon and modeling the bias in dependence on the forecasted irradiance. The accuracy assessment was performed for single stations and for regional average values. At the level of individual stations, the bias removal based on Kalman filtering outperforms the other approach. However, the improvement compared with the original forecasts is small for single stations, while for regional averages both bias removal approaches significantly reduced the RMSE.

#### **2.4.7.3 Temporal interpolation**

Global model forecasts are provided with a temporal resolution of 3 – 6 hours. The management of electricity grids, however, needs forecasts of the expected solar power input at least on an hourly basis. Different interpolation techniques may be applied in order to derive hourly forecasts from global NWP output. Lorenz and al. [57] propose an approach combining the forecast data with a clear-sky model to account for the typical diurnal course of irradiance.

#### **2.4.7.4 Spatial averaging**

Lorenz and al. [57] found that for ECMWF forecasts with an original spatial resolution of 25 km x 25 km and temporal resolution of 3 h, best results are achieved for average values of 4 x 4 grid points corresponding to a region of 100 km x 100 km (Lorenz and al. [57]).

However, the improvement compared with forecasts that evaluate only the next grid point is small due to the already coarse spatial and temporal resolution of the original forecasts.

Spatial averaging has a much stronger impact for mesoscale or multi-scale model output with hourly values and a finer grid resolution. An analysis of the high-resolution WRF forecasts presented in Heinemann and al. [31] showed that averaging irradiance predictions over an area of 180 km x 180 km reduces the RMSE to approximately 85% of the RMSE when evaluating the nearest grid point only. Similar improvements are achieved for WRF forecasts provided by Meteotest that are delivered as average values of 10 x 10 model pixels, corresponding to an area of 50 km x 50 km (Lorenz and al. [57]), and also for irradiance forecasts with the Canadian GEM model, where averaging areas in the range of 300 km x 300 km to 600 km x 600 km gave better results (Pelland et al. [77]). Mathiesen and Kleissl [64] report 100 km x 100 km as a suitable averaging area for irradiance forecasts of GFS model and NAM model.

#### **2.4.7.5 Physical postprocessing approaches**

A few studies also investigate physical postprocessing procedures involving radiation transfer calculations. This allows for integrating additional parameters that are generally not modeled in detail with NWP models, for example, aerosols. A partly physical postprocessing procedure for topographic downscaling of solar irradiance forecasts in mountainous regions is proposed in Lara-Fanego and al.[49]. The disaggregation is carried out by accommodating the initial WRF irradiance estimates to the elevation of a target digital elevation model with a spatial resolution of 90 m x 90 m. The proposed method accounts for shading, sky-view reduction, reflected irradiance, and scaling to the inclined terrain surface.

#### **2.4.8 Human interpretation of NWP output**

Finally, a traditional method to obtain improved local forecasts from NWP model output is the participation of a human forecaster [16]. Meteorologists at weather services routinely analyze and compare the output of different global and local NWP models and meteorological measurements. In particular, they also use their expert knowledge to decide on the final forecast values, for example, of cloud cover. Solar irradiance forecasts may be derived by combining the cloud cover forecasts of meteorologists with a clear-sky model (see section 2.2.1.2). An advantage of this approach is that forecasts may be adjusted for local events or weather situations difficult to forecast with NWP models or statistical methods, like, fog.



## 2.5 Hybrid models

Hybrid models have been introduced to overcome the deficiency of using a individual model such as statistical methods (ARIMA, Multiple Regression and etc.) and AI methods. Hybrid models merge different methods to improve the prediction accuracy. Hybrid models can be also referred as combined models or ensemble models and often these terms are used synonymously. Hybrid methods can be implemented in three different ways ; linear models, nonlinear models and both linear and nonlinear models.

With the intention to improve the forecasting accuracy, the combination of forecasting approaches has been proposed by many researchers ([17], [14], [15], [43], [82]). From their studies, they indicate that the integrated forecasting techniques outperform the individual forecasts.

Artificial intelligence techniques, such as fuzzy logic and neural networks, have been used for estimating hourly global solar irradiance from satellite images. The results seem to point out that fuzzy logic and neural network models are better than regression models.

Cao and Cao in [17] and [14] developed a hybrid model for forecasting sequences of total daily solar irradiance, which combines ANN with wavelet analysis.

Cao and Lin[15] use an ANN (with a special designed training algorithm) combined with wavelets (based on diagonal recurrent wavelet neural network (DRWNN)) to predict next day hourly values of global irradiance. Different types of meteorological observations are used as input to the models ; among others the daily mean global irradiance and daily mean cloud cover of the day are forecasted.

Ji and Chee [43] use a hybrid model of ARMA and TDNN to improve the prediction accuracy. They suppose that the daily solar irradiance series is composed by linear and nonlinear components and use the ARMA model to fit the linear component and the TDNN model to find the nonlinear pattern lying in the residual. This hybrid model has the potential to harness the unique features and strengths of both models. It is more accurate than using the ARMA or TDNN models separately.

## 2.6 Future solar irradiance forecasting approaches for small-scale insular grids

A summary of the literature on solar irradiance forecasting models illustrated by Figure 2.4 and Figure 2.5 gives indications for future work. Figure 2.4 shows the classification of forecasting models based on spatial resolution of input data and temporal resolution of

output or foreseen data. Figure 2.5 illustrates the relation between the forecasting horizons, the forecasting models and the related activities for grid operators.




FIGURE 2.4 Classification of model based on spatial and temporal resolution

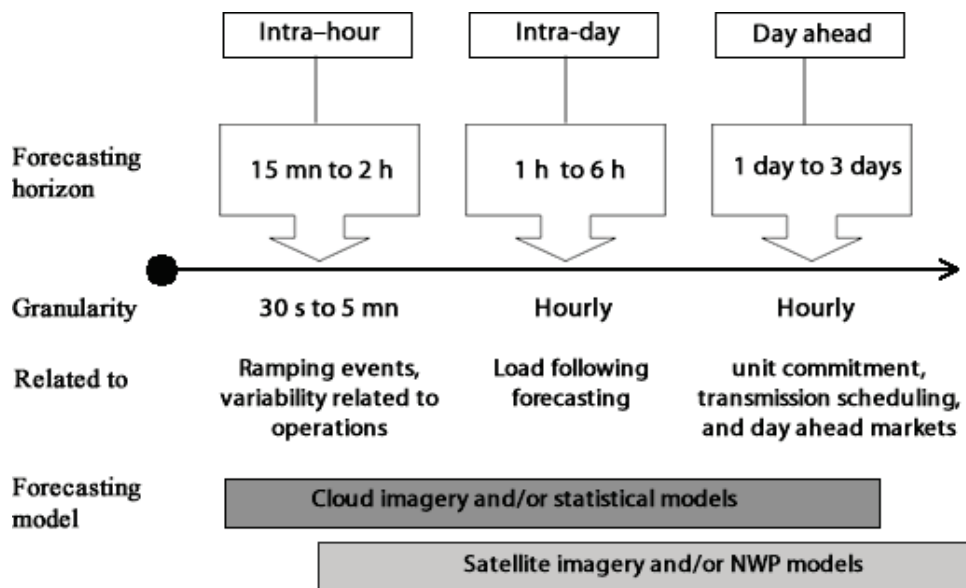


FIGURE 2.5 Relation between horizons, models and activities

However, a further consideration in choosing among forecasting models is efficiency. Reunion Island is a small territory with a high relief, a lot of microclimates and cloud formation processes. In this context, the selection of forecasting model is based on small horizontal and temporal resolution of forecasting model.

Based on these consideration, for day ahead and intra-days forecast horizon, we find that global models like ECMWF and GFS whom present generally reliable results are limited by their coarse resolution for Reunion Island. We suggest to use the mesoscale model WRF. It allows for small horizontal and temporal resolution.

For intra-day and intra-hour forecast horizon time series models are used. The large number of data (GHI) measured on the ground offers a large set of temporal series of irradiance. This time series will permit building a statistical forecasting model. In this forecast horizon, the ARIMA models seem to be the most reliable model. They can provide a forecast in a fraction of a second on a personal computer. However, for an horizon of forecast of a few minutes, the persistence model achieves better accuracy than ARIMA models. In this sense, the choice of the model depends critically on the horizon of forecast. At longer horizons, the data are dominated by the diurnal cycle. In this case ARIMA models work better. At higher frequency, the data is more dominated by short-term patterns which can be picked up by persistence or ANN.

## 2.7 Conclusions

Solar irradiance forecasting is important for the integration of photovoltaic plants into an electrical grid. Proper solar irradiance forecasting helps the grid operators to optimize their electricity production and /or to reduce additional costs by preparing an appropriate strategy.

A number of time series models and numerical weather prediction (NWP) models have been reviewed in this paper. From the description of the various results of solar irradiance forecasting, we maintain that the choice of the appropriate forecasting models depends on forecast horizon and the available data. For forecast horizon from 6 hours up to 3 days ECMWF associated with a MOS post-process shows the most accurate results. However, in the case of Reunion Island, the WRF model seems to be more pertinent. For a smaller forecast horizons, from 5 minutes to 4 hours ARIMA seems to present the best accuracy. Cloud imagery and a hybrid model can improve the results of forecasting when solar irradiance presents a strong variability like in many of insular territories.

It is worth noting that Kostylev and Pavlovski [89] have done extensive analysis of the

best performing models on differing time scales. As stated above, different models are best at different forecast horizons. They give the estimates of the best rRMSE values for both mostly cloudy times and mostly clear. The values range from approximately 17% at one hour, to 22% for three days for mostly clear. For mostly cloudy, they range from 33% to 44% over the forecast range of one to three days.

Future work will include several elements to improve forecast accuracy. Sky image techniques will be used to account for the process of cloud formation. The interesting methods identified here (WRF, ARIMA and AR) will be combined to sky images to yield a comprehensive and more accurate forecast product with different horizons of forecast. A post processing method such as Kalman filtering will be applied in order to improve accuracy of WRF forecasts.

The method we propose will be faced with two limitations. The first is the need to have a high temporal and spatial resolution of the input data. The second, regarding the forecasts to be produced by the NWP models, is the need of high capacity computing power. Concerning post-processing methods, they are exclusively based on statistical properties of the time series and do not use the physical properties of solar irradiance. In the case of ARIMA models one limitation will be then to take into account of physical behavior of time series objects like sunrise and sunset.

The goal is to take care of the needs of grid operators.



# Chapitre 3

## Prévision du rayonnement global à court terme (J+1)

### Sommaire

---

<b>3.1</b>	<b>Vue globale de la méthode proposée</b>	<b>41</b>
<b>3.2</b>	<b>Modèle climatique régional WRF</b>	<b>42</b>
3.2.1	Justification du choix de WRF	42
3.2.2	Présentation générique de WRF	42
3.2.2.1	Choix du cœur dynamique	44
3.2.2.2	Préparation des données (WPS)	44
3.2.2.3	Initialisation du calcul de ARW	45
3.2.2.4	Coordonnées verticales ou niveaux $\sigma$	46
3.2.2.5	Simulation de WRF	47
3.2.2.6	Extraction des données simulées	48
3.2.2.7	Calculs intensifs	48
3.2.3	Protocole expérimental de simulation	48
3.2.3.1	Paramétrisations physiques	51
3.2.3.2	Ressources informatiques	53
3.2.4	Analyse préliminaire du biais	53
<b>3.3</b>	<b>Modèle neuronal</b>	<b>55</b>
3.3.1	Justification du choix neuronal	55
3.3.2	Présentation générale	55
3.3.3	Procédure d'apprentissage	57
3.3.3.1	Phase de préparation	57

---

3.3.3.2	Phase d'apprentissage . . . . .	57
3.3.4	Capacité de généralisation . . . . .	58
3.3.5	Validation simple . . . . .	59
3.3.6	Techniques de régularisation . . . . .	60
3.3.7	Régularisation bayésienne . . . . .	61
3.3.7.1	Estimation des poids et des biais . . . . .	62
3.3.7.2	Optimisation bayésienne des hyperparamètres $\alpha$ et $\beta$ . . . . .	64
3.3.8	Mise en oeuvre du modèle neuronal . . . . .	66
3.3.8.1	Sélection des entrées . . . . .	66
3.3.8.2	Implémentation de l'approche evidence framework . . . . .	67
<b>3.4</b>	<b>Conclusion . . . . .</b>	<b>68</b>

---

### 3.1 Vue globale de la méthode proposée

La prévision du rayonnement solaire global (GHI) pour le jour suivant (J+1) est produite en plusieurs étapes. L'enchaînement de ces étapes est illustré par la figure 3.1. D'abord, les prévisions du modèle global GFS produites à 00h UTC sont téléchargées depuis le site web du NCEP. Elles sont utilisées comme données d'entrée du modèle WRF dans l'objectif d'affiner en terme de résolution spatiale et temporelle les prévisions du modèle GFS. Enfin, la qualité des prévisions du modèle WRF est améliorée à partir d'une méthode d'apprentissage s'appuyant sur des données mesurées au sol.




FIGURE 3.1 Vue globale de la démarche J+1

Le séquençage temporel ou relation entre les horizons de prévision et les heures locales correspondantes est illustré par la Figure 3.2.

Ainsi, pour produire une prévision J+1 avec une configuration stable de WRF, il a fallu faire 32 h de prévision allant de t+1h à t+32h. Les huit premières heures soit de t+1h à t+8h ne sont pas prises en compte afin de laisser au modèle le temps de se stabiliser. Les 24 h de prévisions suivantes, soit de t+9h à t+32h, représentent la prévision J+1 au pas de temps horaire.




FIGURE 3.2 Séquençage temporel de la démarche J+1



Les prévisions de WRF sont ensuite améliorées par post-traitement avec un réseau de neurones artificiel.

## 3.2 Modèle climatique régional WRF

Dans cette section, nous présentons les caractéristiques du modèle méso-échelle WRF utilisé par la suite. Le propos est plutôt technique, mais il nous est paru intéressant de détailler quelque peu le fonctionnement du cœur dynamique d'un tel modèle. Le but n'est pas de reproduire avec exhaustivité la description d'un modèle dont les caractéristiques sont par ailleurs bien documentées [86].

### 3.2.1 Justification du choix de WRF

L'université de La Réunion ne dispose pas de modèles de prévisions météorologiques opérationnels. En effet, le modèle Meso-NH [48] n'est pas opérationnel et affiche un coût de calcul prohibitif pour réaliser une simulation annuelle. Arome [84], seul modèle expérimental actuellement disponible pour l'île de La Réunion, est limité au projet PEGASE<sup>1</sup>. Par conséquent, nous avons choisi d'utiliser le modèle WRF pour faire les prévisions du GHI. Il est libre, dispose d'une communauté scientifique dynamique et les données d'initialisation sont faciles à acquérir.

### 3.2.2 Présentation générique de WRF

Le Modèle Weather Research and Forecasting (WRF) [86] est un modèle méso-échelle de nouvelle génération conçu par le National Center for Atmospheric Research (NCAR), la National Oceanic and Atmospheric Administration, la Air Force Weather Agency (AFWA), le Naval Research Laboratory, la Oklahoma University et la Federal Aviation Administration (FAA) pour prévoir et modéliser la circulation atmosphérique. Il est disponible en téléchargement gratuit sur le site web officiel<sup>2</sup> de WRF.

WRF est un modèle de météorologie tridimensionnel non-hydrostatique, c'est-à-dire tenant compte de l'accélération verticale dans l'atmosphère, qui repose sur les équations de la mécanique des fluides et de la thermodynamique. Il permet le calcul des composantes horizontales et verticales du vent, de la température potentielle, du taux de mélange de vapeur d'eau, de la densité de l'air sec et du géopotential. Il utilise les coordonnées sigma

1. PEGASE signifie Prévision des énergies renouvelables et garantie active par le stockage d'énergie.

2. Site officiel de téléchargement de WRF <http://www.mmm.ucar.edu/wrf/users/downloads.html>

sur la verticale définies à partir de la pression de référence et résoud les processus physiques de précipitation, de diffusion, de rayonnement et de convection. Au niveau de l'interface sol/atmosphère, WRF prend en compte la tension de frottement et les flux de chaleur sensible et d'évaporation. La connaissance de certaines variables d'état au sol comme la rugosité, la température, la présence de neige et l'humidité est nécessaire pour simuler la circulation atmosphérique.

Des données météorologiques provenant d'un modèle global et des données statiques, telles que des données de topographie, végétation, eau, type de sol, albédo et de température annuelle moyenne, sont nécessaires au modèle WRF pour décrire l'évolution de la circulation atmosphérique. En ce qui concerne les données météorologiques utilisées pour l'initialisation et pour les conditions aux limites, il s'agit entre autres des composantes du vent, de la température potentielle et du taux d'humidité issues de données opérationnelles de prévision du NCAR et du NCEP (National Centers for Environmental Prediction).

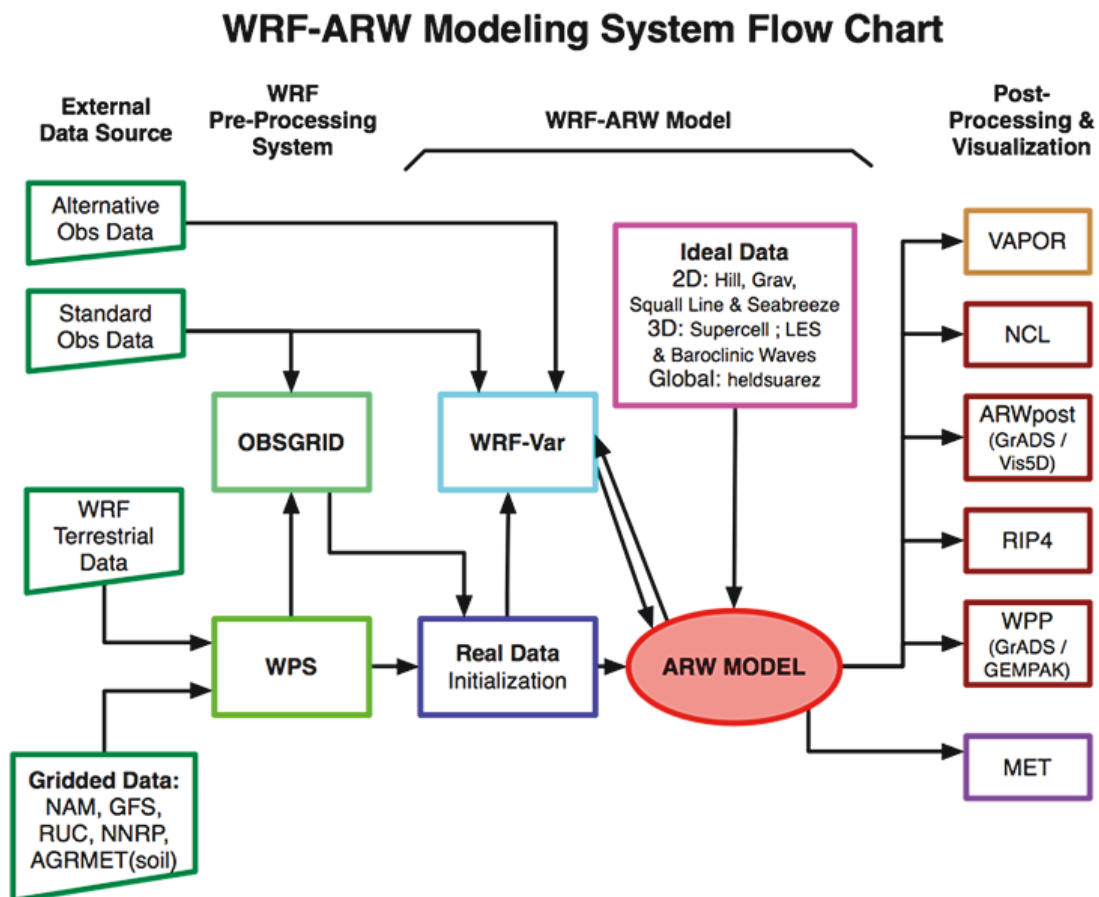


FIGURE 3.3 Organigramme du cœur dynamique ARW de WRF [92].

### 3.2.2.1 Choix du cœur dynamique

Le modèle WRF propose deux noyaux qui diffèrent selon l'utilisation souhaitée. Le noyau Non-Hydrostatic Meso-scale Model (NMM) est développé par le NOAA/NCEP pour la prévision opérationnelle, alors que le noyau Advanced Research WRF (ARW) est développé par le NCAR pour la recherche climatique. Véritable plate-forme de recherche pour la simulation numérique du climat, le cœur dynamique ARW offre une large gamme de configurations, allant de cas idéalisés en 2D et 3D au mode dit réel alimenté aux bornes par des données simulées de large échelle (Modèles climatiques globaux, données réanalysées, ...) avec la possibilité d'assimiler des observations terrestres et satellitaires.

Les simulations réalisées dans ce travail sont exclusivement produites à partir du cœur dynamique ARW qui est représenté par la Figure 3.3. En effet, il est adapté pour gérer de gros volumes de données en mode réel et pour désagréger<sup>3</sup> les champs atmosphériques fournis par le modèle global GFS. Les objectifs de la thèse exigeant de désagréger ces données à très haute résolution, le noyau ARW est configuré en two-way nesting, et trois domaines imbriqués sont simulés pour affiner les résolutions.

### 3.2.2.2 Préparation des données (WPS)

Afin d'initialiser WRF en surface et à chaque niveau atmosphérique et pour le forcer aux bornes latérales, le pré-traitement des données utilisées est faite avec une suite de logiciels appelée WPS ou WRF Preprocessing System. WPS est composée de trois sous-programmes, « *geogrid* », « *ungrib* » et « *metgrid* », correspondant à trois étapes successives et nécessaires à la préparation des données. L'organisation de ces programmes est illustrée par la Figure 3.4. Leur configuration est faite dans les fichiers *namelist.wps* et *namelist.input* disponibles dans l'Annexe A.




FIGURE 3.4 Étapes de la préparation des données [92].

L'enchaînement des étapes dans la préparation des données se présente comme suit :

3. Désagréger signifie faire de la descente d'échelle.

– **Étape 1 (*geogrid*)**

La première étape correspond au programme *geogrid*. Il est configuré à l'aide du fichier *namelist.wps*. Dans ce fichier est défini le noyau dynamique à utiliser (ARW ou NMM), le nombre de domaines à simuler, leurs tailles, leurs localisations, le type de projection cartographique et la résolution horizontale du (des) domaine(s).

Le fichier *namelist.wps* permet également de sélectionner les données de surface (principalement les types de sol, occupation du sol, moyenne annuelle de la température des couches profondes du sol, altitudes, pentes, fraction végétale et albédo) disponibles à différentes résolutions (10m-arc, 5m-arc, 2m-arc ou 30sec-arc), et de les interpoler à la résolution du modèle. Ces données ne varient pas dans le temps, elles sont dites statiques, et sont fournies par l'United States Geological Survey [88]. Elles décrivent 24 catégories d'occupation du sol déterminées à partir de moyennes climatologiques et 16 catégories de types de sol recensées par l'United Nations Food and Agriculture Organization. *Geogrid* pondère chaque catégorie d'occupation du sol et de type de sol par la superficie occupée dans chaque maille WRF ;

– **Étape 2 (*ungrib*)**

La deuxième étape correspond au programme *ungrib*. Il est configuré à l'aide du fichier *namelist.input*. Ce fichier renseigne sur la période d'extraction des données, le pas de temps entre chaque extraction et extrait les données dynamiques (variables météorologiques, de surface terrestre telle que l'humidité du sol, ...) de large échelle utilisées pour fixer les conditions aux bornes latérales et en surface ;

– **Étape 3 (*metgrid*)**

La troisième étape correspond au programme *metgrid*. Elle consiste à interpoler horizontalement les champs extraits avec le programme «*Ungrib*» sur la (les) grille(s) définie(s) avec le programme *geogrid*. De nombreuses méthodes d'interpolation sont disponibles. Se référer à Wang et al. (2009) pour plus de détails.

### 3.2.2.3 Initialisation du calcul de ARW

Une fois les données préparées avec WPS, la simulation de WRF avec le noyau ARW est initialisée. Cette étape fait appel au programme *real*. Il est configuré dans le fichier *namelist.input*. Le programme *real* permet de définir les coordonnées verticales exprimées en niveaux sigma  $\sigma$  (voir section suivante). WRF propose une discrétisation verticale en 28 ou 35 niveaux  $\sigma$ , et laisse la possibilité d'en définir d'autres. La densité du nombre de niveaux est fonction de l'éloignement à la surface, de manière à mieux renseigner les basses couches soumises à une dynamique plus bruitée que les hautes couches, davantage

impactées par la circulation large échelle.

Les champs atmosphériques du modèle forceur fournis en niveaux pression sont alors interpolés sur les coordonnées verticales en niveau  $\sigma$ , et utilisés pour renseigner chaque maille du domaine afin d'initialiser les conditions atmosphériques. Certaines variables surfaciques, principalement l'humidité du sol et sa température, sont également interpolées en fonction du nombre de couches. Ces données, de même que les données statiques, permettent d'initialiser les données de surface, en tenant compte de la topographie et de la projection cartographique.

### 3.2.2.4 Coordonnées verticales ou niveaux $\sigma$

WRF est un modèle de météorologie tridimensionnel non-hydrostatique basé sur les équations compressibles et non hydrostatiques d'Euler. Les équations sont exprimées en coordonnées sigma ( $\sigma$ ) qui sont définies à partir de la pression de référence comme suit :

$$\sigma = \frac{p_0 \times p_{top}}{p_s \times p_{top}} \quad (3.1)$$

où  $p_0$  est la composante hydrostatique de la pression à la hauteur considérée,  $p_s$  est la pression au sol et  $p_{top}$  est la pression au sommet de l'atmosphère.




FIGURE 3.5 Coordonnées verticales en niveaux  $\sigma$  [86].

Les valeurs de  $\sigma$  sont comprises entre 0 et 1. La valeur 0 correspond à la couche supérieure du domaine de calcul et la valeur 1 à la couche inférieure.

Le niveau  $\sigma$  a l'avantage de suivre la pression hydrostatique verticale (topographie), tel qu'illustré par la Figure 3.5. Il est fréquemment utilisé dans les modèles de climat. L'avantage par rapport aux niveaux pression, est de mieux prendre en compte la topographie. Le premier niveau vertical de la Figure 3.5 correspond à la surface. Le dernier correspond à la borne verticale la plus élevée du domaine simulé, et est constant quelle que soit la maille considérée. Cette représentation verticale permet d'assurer la contrainte de continuité en prenant mieux en compte la morphologie du relief pour résoudre les équations de la mécanique des fluides. Les paramètres de configuration sont tous définis dans le fichier *namelist.input*.

### 3.2.2.5 Simulation de WRF

Pour mener à bien les simulations, le noyau dynamique ARW s'appuie sur la formulation non-hydrostatique des équations de la mécanique des fluides et de la thermodynamique. Ces équations sont résolues sur une grille Arakawa C illustrée par la Figure 3.6. Chaque carré représente une maille horizontale du domaine. U et V sont respectivement les composantes zonale et méridienne du vent.  $\theta$  représente toutes les autres variables. Ainsi, les champs dynamiques tels que les composantes zonale et méridienne du vent (U et V respectivement) sont résolues sur la jonction des mailles. Toutes les autres variables (variables thermodynamiques, scalaires et de masse) sont résolues au centre de chaque maille.




FIGURE 3.6 Grille Arakawa C.

### 3.2.2.6 Extraction des données simulées

Une fois l'intégration terminée, chaque simulation est traitée avec le logiciel NCL<sup>4</sup> [74] pour calculer les moyennes quotidiennes des paramètres archivés, et transformer les paramètres atmosphériques en niveau pression.

### 3.2.2.7 Calculs intensifs

WRF est codé en langages fortran 90/95 et C, et est massivement parallélisé, de manière à répartir la charge de calcul sur plusieurs cœurs-processeurs-nœuds de calcul. Les multiples tâches de calcul nécessitent des communications entre ces cœurs-processeurs-nœuds pour la synchronisation des calculs et l'échange d'information. Cela se fait à partir du protocole implémenté dans la librairie MPI (Message Passing Interface) lorsqu'on utilise de la mémoire distribuée (distributed memory) entre plusieurs processeurs d'un unique nœud de calcul, et/ou avec la librairie Open MPI lorsqu'on utilise de la mémoire partagée (shared memory) entre plusieurs nœuds de calcul. Même si la parallélisation massive permet de réduire les temps de calcul, l'utilisation intensive du modèle WRF est seulement réaliste dans un environnement de calcul scientifique intensif, i.e. au sein de supercalculateurs ou de grappes/fermes (cluster) de calcul. Son utilisation nécessite également des ressources mémoire importantes et un espace de stockage conséquent.

## 3.2.3 Protocole expérimental de simulation

Toutes les prévisions sont réalisées avec la version 3 (3.1.1) du modèle WRF en mode non-hydrostatique sur le domaine centré au point de coordonnées géographiques 21° 20 S, 55° 29 E. Ce domaine est illustré par la Figure 3.7. Il a une résolution spatiale horizontale de 3 km et une distribution variable de 100 niveaux verticaux allant approximativement de 0 m à 20 km soit une zone de pression allant de 101325 Pa ou niveau du sol à 5000 Pa ou couche supérieure du troposphère. La résolution verticale est configurée avec une forte densité des niveaux à proximité du sol.

La résolution temporelle des sorties du modèle WRF est configurée à 5 mn afin d'avoir les plus d'informations possibles sur le GHI. Ensuite, la sortie est moyennée au pas de temps horaire puisqu'on s'intéresse à une prévision à court terme. Les simulations du modèle WRF sont faites sur une période de 2 ans qui s'étend du 1er Janvier 2011 au 31 Décembre

---

4. NCL signifie NCAR Command Language. Il est disponible en téléchargement sur le site web <http://www.ncl.ucar.edu/>

2012 soit 730 simulations. Chaque simulation réalise 32 h de prévisions météorologiques. Elle produit des prévisions allant de 16 h le jour J à 00 h le jour J+2 comme illustré par la Figure 3.2. Les huit premières heures de simulation servent de période d'équilibrage (spin-up) temporel. Les 24 h de simulations suivantes qui représentent la prévision J+1 sont retenues dans le cadre de notre étude. Les conditions latérales sont imposées par les données GFS de résolution  $0,5^\circ$  calculées à 00 h UTC. Elles sont disponibles sur le site web<sup>5</sup> du NCEP [73].




FIGURE 3.7 Position des domaines imbriqués dans l'Océan Indien.

La résolution spatiale la plus fine est de  $3 \text{ Km} \times 3 \text{ Km}$ . Elle correspond à un domaine qui couvre l'île de La Réunion qui a une superficie de  $2504 \text{ km}^2$  (disque  $\approx 60 \text{ km}$  de diamètre). Cette résolution est le résultat d'une descente d'échelle qui a mis en jeu 3 domaines imbriqués. En effet, la désagrégation avec le modèle WRF exige le respect d'un ratio de 3 ou 5 entre la taille des pixels des grilles de deux domaines consécutifs imbriqués. Par conséquent, trois domaines imbriqués de résolution horizontale respective de 27, 9 et 3 km, soit un ratio de 3, ont été utilisés dans cette étude pour avoir une résolution fine du domaine simulé. La figure 3.7 présente l'étendue des trois domaines imbriqués .

5. Lien de téléchargement des données GFS : <http://www.ncdc.noaa.gov/data-access/model-data/model-datasets/global-forecast-system-gfs>



La Figure 3.8 illustre plusieurs zooms sur l'imbrication des mailles des trois domaines.

- **Le domaine 1**, avec la résolution horizontale de 27 km x 27 km, couvre une aire géographique relativement étendue qui comprend La Réunion, Maurice et se rapproche de la côte Est de Madagascar. La largeur du domaine est importante afin d'intégrer une grande partie de l'Océan indien. Ce large domaine assure une bonne représentation des systèmes météorologiques synoptiques qui balaient l'île de La Réunion d'est en ouest.
- **Le domaine 2**, moins étendu, est composé de mailles de 9 km x 9 km. Il couvre La Réunion et se rapproche de la côte ouest de Maurice. Une grande distance entre le domaine 1 et le domaine 2 est nécessaire avant que la dynamique de l'échelle large développe des traits du climat d'échelle plus fine.
- **Le domaine 3**, avec une résolution horizontale de 3 km x 3 km, couvre La Réunion et est centré sur l'IUT de Saint Pierre où une station météo est disponible.

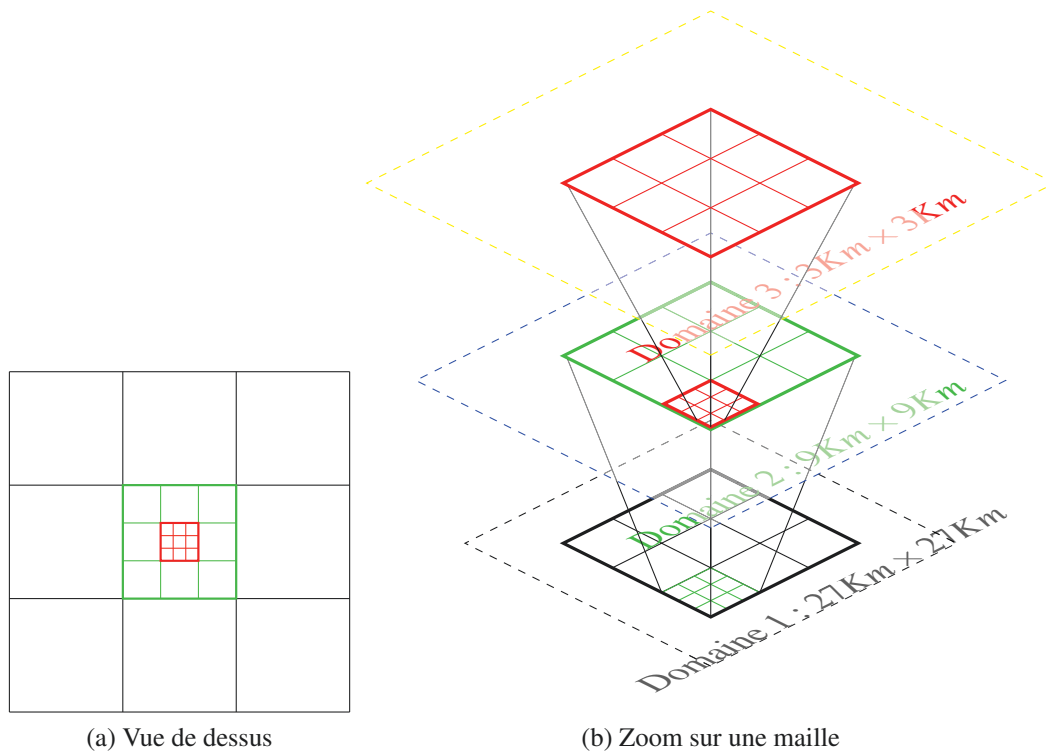


FIGURE 3.8 Résolution horizontale des trois domaines imbriqués

Le modèle WRF propose trois types de projections à savoir la projection Lambertienne conforme polaire, la projection polaire stéréographique et la projection Mercator. Cette dernière est une projection cylindrique tangente à l'équateur du globe terrestre sur une carte

plane. Elle engendre des distorsions négligeables autour de l'équateur. La projection Mercator est donc la projection la plus adaptée à la latitude de La Réunion.

### 3.2.3.1 Paramétrisations physiques

Le modèle WRF propose de nombreuses configurations pour les principaux schémas physiques implémentés à savoir la microphysique des nuages, la couche limite planétaire, l'interaction surface continentale-atmosphère et le rayonnement courtes et grandes longueurs d'ondes. La suite de cette section est consacrée à la présentation des paramètres utilisés et définis dans les fichiers *namelist* disponibles dans l'Annexe A.

#### – Microphysique des nuages

La microphysique des nuages couvre les processus de vapeur d'eau, de formation de nuages et de précipitation. Dans nos simulations, nous avons utilisé le modèle microphysique Single-Moment 3-class [35]. Il comprend les processus de formation de la glace et de la neige ainsi que les processus de phases mixtes (par exemple eau-glace) et tient compte également de l'eau dans l'état surfondu.

#### – Modèle de cumulus

Les schémas de paramétrisation des cumulus ont notamment pour rôle de représenter les flux verticaux engendrés par les courants ascendants et descendants des petites cellules convectives. Le schéma de Kain-Fritsch [44] est appliqué en se fondant sur les flux convectifs d'humidité ascendants et descendants incluant des effets de scission et de fusion de courants de vents.

#### – Modèle de couche de surface

Les schémas de couche de surface permettent les calculs des vitesses de friction et des coefficients d'échanges rentrant en jeu dans l'évaluation des flux de chaleur et d'humidité par le modèle de surface et le modèle de couche limite.

Dans notre étude, le schéma de couche de surface est basé sur la théorie des similitudes selon la paramétrisation Similarity theory (MM5) [76]. La théorie de la similitude consiste à énoncer que si les conditions de deux expériences sont identiques alors leurs résultats sont aussi identiques. On lui doit une grande partie des connaissances actuelles sur la couche limite atmosphérique notamment depuis l'énoncé historique de Monin and Obukhov [71].

#### – Modèle de surface terrestre

Les modèles de surface utilisent l'information obtenue par les schémas de couche de surface, le forçage radiatif obtenu par les schémas de rayonnement, l'information sur le taux de précipitation issu de la microphysique ainsi que les données statiques

introduites dans le modèle WRF (type de sol , végétation, ...) afin de fournir les flux de chaleur et d'humidité sur la terre et la mer. Ils permettent par la suite de mettre à jour les variables au sol comme la température. Ces flux constituent les conditions aux limites inférieures du modèle de couche limite planétaire. Le schéma Noah [87] est utilisé dans notre étude. Il est le successeur du schéma OSU décrit par Chen and Dudhia [18]. Il comprend 4 couches de sol en température et humidité situées à 10, 30, 60 et 100 centimètres de profondeur. Les processus pris en compte sont l'évaporation, le drainage du sol et l'écoulement, selon le type de végétation présente et le type de sol.

#### – **Modèle de couche limite planétaire**

Les schémas de couche limite planétaire permettent de paramétrer la diffusion verticale turbulente au sein de la colonne d'air. Ils déterminent les profils de flux à l'intérieur de la couche limite mélangée et la couche stable et ainsi fournissent les tendances pour la température, l'humidité, les composantes horizontales du vent pour toute la colonne d'air.

A partir des flux communiqués par la couche de surface, le modèle de couche limite calcule les profils verticaux de chaleur et d'humidité (aux échelles inférieures à la grille du modèle) dus aux transports tourbillonnaires (Eddy flux ). On en déduit ainsi des tendances de température, d'humidité et de transport horizontal le long de la colonne atmosphérique. La paramétrisation choisie est la Yonsei University PBL décrite par Hong [36]. L'estimation des flux turbulents dépend tout particulièrement de l'évaluation de la hauteur de la couche limite. Celle-ci est déterminée dans le modèle à partir du profil vertical du nombre de Richardson<sup>6</sup>. La hauteur à partir de laquelle le nombre de Richardson devient positif (= effets de la turbulence négligeables) correspond au sommet de la couche limite planétaire.

#### – **Module radiatif**

Les schémas de rayonnement ont pour but d'estimer le réchauffement de l'atmosphère dû aux rayonnements ondes courtes et ondes longues. Le module radiatif fournit les flux descendants et montants pour les courtes et grandes longueurs d'ondes au sommet de l'atmosphère et au niveau du sol. On en déduit ainsi l'échauffement/refroidissement de l'atmosphère à partir de la convergence/divergence de ces flux radiatifs. Il est à noter que le flux montant au niveau du sol provient, pour les grandes longueurs d'ondes, de l'émissivité de la surface terrestre qui dépend du type

---

6. Le nombre de Richardson est le rapport entre l'énergie cinétique créée par effet thermique et celle créée par effet dynamique

de sol et de sa température. Pour les courtes longueurs d'ondes il provient du rayonnement solaire réfléchi par la surface.

Dans le domaine des courtes longueurs d'ondes, le schéma utilisé est le schéma de Dudhia [24], alors que celui pour les grandes longueurs d'ondes est le Rapid Radiative Transfer Model (RRTM) Longwave [70] incluant 16 bandes spectrales. Les flux radiatifs sont calculés sous l'hypothèse d'une atmosphère plan-parallèle où l'on néglige le rayon de courbure de la Terre, ce qui est une bonne approximation lorsque la résolution verticale du modèle est très supérieure à la résolution horizontale. Le module radiatif utilise également en entrée des moyennes mensuelles de l'albédo de la surface terrestre issues du NCEP. Le pas de temps du modèle radiatif est fixé à 3 minutes.

La configuration complète du modèle WRF à travers les fichiers *namelist.wps* et *namelist.input* est disponible dans l'annexe A.

### 3.2.3.2 Ressources informatiques

Toutes les simulations ont été faites sur le cluster TITAN du CCUR<sup>7</sup> dont les performances n'ont cessé de croître depuis le début de ces travaux de thèse. A la fin de l'année 2011, TITAN comprend 26 nœuds de calcul dont 22 sont dédiés aux calculs parallèles. Ces derniers disposent de 684 Go pour l'exécution des travaux et 54 To pour le stockage. La puissance crête est estimée à 1.92 Teraflops, soit environ 1920 milliards de calculs par seconde. Le cluster est équipé en processeurs INTEL Xeon avec une architecture SMP<sup>8</sup>. Le système d'exploitation est une base Linux. Le logiciel PBS [32] organise l'exécution des programmes soumis par les utilisateurs sur le cluster. Il permet de soumettre des travaux en arrière plan (batch) à partir des machines interactives, de répartir automatiquement les calculs sur l'ensemble des machines du cluster afin d'en exploiter la puissance de manière optimale, et de gérer les files d'attente.

Une analyse préliminaire des prévisions faites avec le modèle WRF et les ressources informatiques du CCUR est présentée dans la section suivante.

### 3.2.4 Analyse préliminaire du biais

Dans un premier temps, les prévisions au pas de temps horaire du GHI à l'horizon J+1 sont comparées aux mesures faites au sol pour la station de Saint Pierre. Cette comparaison,

7. CCUR signifie Centre de Calcul de l'Université de La Réunion

8. SMP signifie Symmetric Multiprocessing.

illustrée par la Figure 3.9, montre que les prévisions du modèle WRF ne donnent pas une bonne précision.




FIGURE 3.9 Comparaison des prévisions WRF à l'horizon t+24h aux mesures réelles.

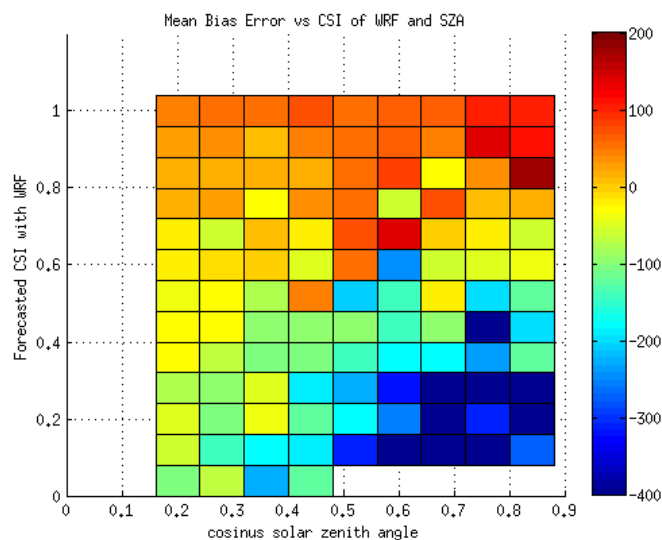


FIGURE 3.10 Variation du biais prévisionnel  $k_t^*$  en fonction de  $\cos(\text{SZA})$ .

Une étude plus approfondie des prévisions du modèle WRF est présentée à la section 5.3.2. L'analyse du biais et les performances du modèle WRF ainsi que l'étude bibliographique nous ont amené à appliquer un post-traitement avec un réseau de neurones artificiel. L'objectif de ce post-traitement est d'améliorer les performances de prévision.

### 3.3 Modèle neuronal

Cette partie est consacrée à une brève présentation des réseaux de neurones artificiels (RNA). Il s'ensuivra une présentation succincte de la procédure d'apprentissage et de la capacité de généralisation. La dernière partie est consacrée à la gestion de la complexité de l'architecture du RNA et à la sélection des variables d'entrée pertinente avec l'approche bayésienne. Une présentation plus générale des RNA et de leurs applications est disponible dans Dreyfus et al. [23].

#### 3.3.1 Justification du choix neuronal

Le choix des RNA est justifié par ses deux propriétés fondamentales. D'une part, Les RNA sont des approximateurs parcimonieux [38]. En effet, Hornik montre que l'approximation dépend de la manière dont les paramètres internes sont introduits dans le modèle. Plus précisément, pour un même problème et une précision donnée, le modèle dont la sortie est non linéaire par rapport à ses paramètres internes a besoin de moins de paramètres que tout autre modèle, tel que les polynômes, dont la sortie est linéaire à ses paramètres internes. Cette propriété fondamentale des RNA à approcher des fonctions non linéaires avec le moins de paramètres possible est appelée «parcimonie». D'autre part, les RNA sont des approximateurs universels [37]. En effet, ils peuvent modéliser le comportement de n'importe quelle fonction à condition d'avoir suffisamment de neurones cachés.

Par conséquent, les RNA ont été choisis pour corriger le biais systématique présent dans les prévisions du modèle numérique WRF. Ce choix est motivé par la capacité du RNA à modéliser la relation non linéaire existante entre le biais et les variables d'entrées  $k_i^*$  et le cosinus de l'angle solaire zénithal  $\cos(SZA)$ . Cette relation a été mise en évidence par l'analyse préliminaire du biais présentée à la section 3.2.4.

#### 3.3.2 Présentation générale

Les réseaux de neurones sont des algorithmes inspirés de la biologie. Ils visent à reproduire les capacités d'apprentissage et de reconnaissance du cerveau. Par définition, un RNA est constitué d'un ensemble de cellules simples et fortement interconnectées appelées neurones. Chaque neurone effectue une transformation non linéaire de la somme pondérée de ses entrées avec la fonction d'activation<sup>9</sup>. Les coefficients de pondération ou poids  $w_i$

9. La fonction d'activation  $f$  est généralement représentée par la fonction tangente hyperbolique.

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

détiennent la connaissance du réseau. La fonction d'activation  $f$  est associée à chaque neurone caché. Elle est une fonction paramétrée non linéaire à valeurs bornées et admet comme argument la somme du biais  $b$  et des entrées  $x_i$  pondérées par les poids  $w_i$ . La Figure 3.11 illustre la représentation graphique du neurone formel.

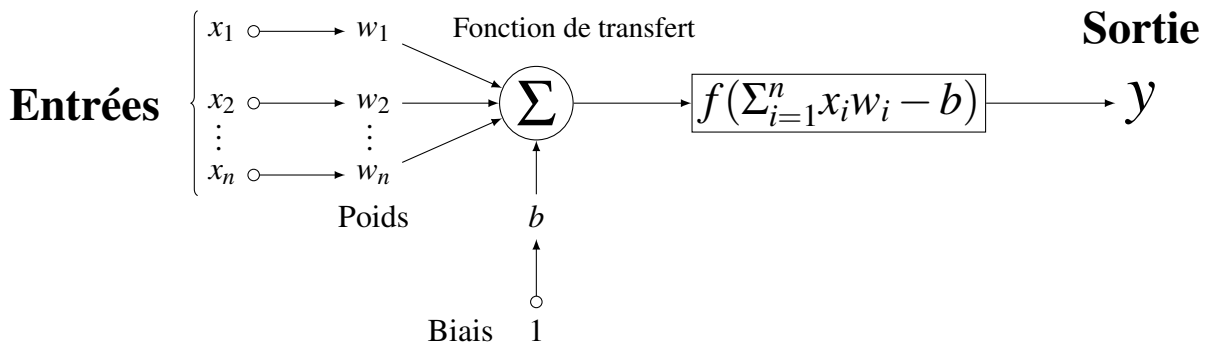


FIGURE 3.11 Neurone formel

Un RNA simple est constitué de couches de neurones où chaque neurone d'une couche est relié à tous les neurones de la couche supérieure. La couche inférieure, appelée "couche d'entrée", reçoit les données  $x_i$ , la couche supérieure, appelée "couche de sortie", donne le résultat ou sortie du neurone  $y$ . Les couches intermédiaires sont appelées "couches cachées". La Figure 3.12 illustre cette architecture qui porte le nom de perceptron multicouche ou MLP.




FIGURE 3.12 Perceptron Multicouche

Connaissant la structure du réseau c'est-à-dire les interconnexions, l'idée est de trouver les poids qui minimisent la différence entre les valeurs délivrées par le réseau et les valeurs désirées. Ces dernières font partie d'une base dite base d'apprentissage. Les valeurs des poids  $w_i$  sont identifiées durant la procédure d'apprentissage.

### 3.3.3 Procédure d'apprentissage

La procédure d'apprentissage est composée d'une phase de préparation et d'une phase d'apprentissage.

#### 3.3.3.1 Phase de préparation

Pour éviter qu'une variable d'entrée ne soit prépondérante par rapport à une autre de par son ordre de grandeur et aussi éviter en pratique des problèmes numériques, il est conseillé de normaliser les données avant de procéder à l'apprentissage. Une solution de normalisation est de calculer la moyenne  $\mu_i$  et l'écart-type  $\sigma_i$  de ses composants en vue d'avoir la moyenne de chaque variable proche de zéro et l'écart-type de l'ordre de 1 [23]. De plus, les entrées centrées accélèrent la convergence de l'apprentissage. En effet, les fonctions d'activation des neurones non linéaires doivent fonctionner dans leur zone centrale quasi-linéaire où leur dérivée est maximale, sinon, leur influence sur les variations de l'erreur quadratique moyenne est faible. Dans ce contexte, nous avons utilisé comme solution de normalisation l'indice de ciel clair en entrée du RNA au lieu du GHI. En effet, la valeur de l'indice de ciel clair  $k_i^*$  varie entre 0 et 1 alors que celle du GHI varie entre 0 et 1700. De même, le cosinus de l'angle solaire zénithal est utilisé à la place du SZA. Le choix des entrées pertinentes du RNA est présenté à la section 3.3.8.1.

De plus, les poids et biais du réseau doivent être initialisés. Cependant, une mauvaise initialisation peut faire converger le réseau vers un minimum local au détriment de la solution optimale. Une fois les entrées normalisées et les poids initialisés, la prochaine étape est de procéder à l'apprentissage.

#### 3.3.3.2 Phase d'apprentissage

La phase d'apprentissage revient à estimer les paramètres  $w$  qui minimisent une fonction de coût des moindres carrés  $E_D$  constituée par la somme des écarts quadratiques entre la



sortie du modèle  $y_i$  et la mesure  $t_i$ .

$$E_D(w) = \frac{1}{2} \sum_{i=1}^N (y_i(w) - t_i)^2 = \frac{1}{2} \sum_{i=1}^N e_i^2 \quad (3.2)$$

Avec  $y_i$  représentant la sortie du modèle,  $t_i$  la mesure,  $N$  le nombre de mesures et  $t_{i=1..N}$  la base d'apprentissage.

L'apprentissage tend à minimiser l'erreur  $E_D$  du réseau par rapport aux exemples de la base d'apprentissage. Cependant, l'objectif ultime de la procédure d'apprentissage est de rendre le RNA capable d'estimer la sortie du système réel modélisé lorsque celui-ci est soumis à des entrées absentes de la base d'apprentissage. Cette aptitude à prédire le comportement du système est appelée capacité de généralisation.

### 3.3.4 Capacité de généralisation

La capacité de généralisation dépend de la complexité du modèle (c'est-à-dire du nombre de neurones cachés). En effet, un nombre de neurones trop faible conduira à un mauvais apprentissage (phénomène de sous-paramétrisation). En revanche, si le réseau possède un trop grand nombre de neurones cachés donc un grand nombre de paramètres internes, cela va conduire à un surparamétrisation ou sur-ajustement. La relation entrée-sortie construite par l'apprentissage présente alors souvent, en dehors des exemples appris, de fortes variations inexplicables. Malgré l'importance de ce problème, il n'existe pas, à ce jour, de méthodes fiables pour déterminer l'architecture du RNA en fonction du problème à traiter. L'utilisateur des RNA doit donc déterminer le nombre de neurones de la couche cachée durant la phase d'apprentissage.

En règle générale, l'erreur quadratique moyenne calculée sur la base d'apprentissage (erreur d'apprentissage) diminue avec l'augmentation de la taille du RNA. En revanche, après une phase initiale de décroissance, l'erreur quadratique moyenne calculée sur des exemples autres que ceux de la base d'apprentissage (erreur de généralisation) tend à diverger quand la taille du RNA devient excessive (apparition de sur-apprentissage).

Pour éviter le problème de sur-apprentissage, différentes méthodes sont proposées [51]. Nous allons présenter trois des méthodes les plus connues, à savoir la validation simple, la régularisation par modération des poids et la régularisation bayésienne.

### 3.3.5 Validation simple

La validation simple [23] est souvent appliquée en raison de sa facilité d'utilisation. Elle ne demande pas d'algorithme particulier. Les données utilisées pour la modélisation du RNA sont divisées en trois ensembles :

- Un ensemble d'apprentissage où les poids et biais internes du réseau sont ajustés de tel sorte que l'erreur d'apprentissage soit minimale ;
- Un ensemble de validation disjoint de l'ensemble d'apprentissage qui permet de déterminer le nombre optimal de neurones cachés pour éviter le phénomène de sur-paramétrisation. Il est utilisé pour comparer les performances des modèles du point de vue de leur aptitude à généraliser ;
- Un ensemble de test, disjoint des deux précédents, qui sert à évaluer la performance du modèle sélectionné.

La Figure 3.13 illustre ces trois ensembles de données.




FIGURE 3.13 Validation simple

La procédure d'apprentissage par validation simple est composée de trois étapes. D'abord les trois bases de données sont créées. Ensuite, la base d'apprentissage est utilisée pour entraîner plusieurs modèles RNA qui diffèrent par leur nombre de neurones cachés. A la fin de l'apprentissage, l'erreur de chaque modèle est calculée sur la base de validation. L'évolution de l'erreur de prévision en fonction de la taille du réseau est illustrée par la Figure 3.14.

Le modèle avec la plus faible erreur sur la base de validation est retenu. En dernier lieu, la qualité du modèle neuronal est testée avec la base de données test.

Bien que cette méthode soit très largement utilisée, son temps de mise en œuvre peut être très long. En effet, l'exploration de plusieurs tailles de RNA pour trouver l'erreur minimale sur la base de validation a un coût de calcul important. En réponse à ce problème de coût, l'apprentissage par la régularisation propose d'éviter le surajustement par limitation de l'amplitude des paramètres (valeur des poids). En effet, elle ne cherche pas à contrôler la complexité du réseau car la valeur des poids est plus importante que leur nombre dans la

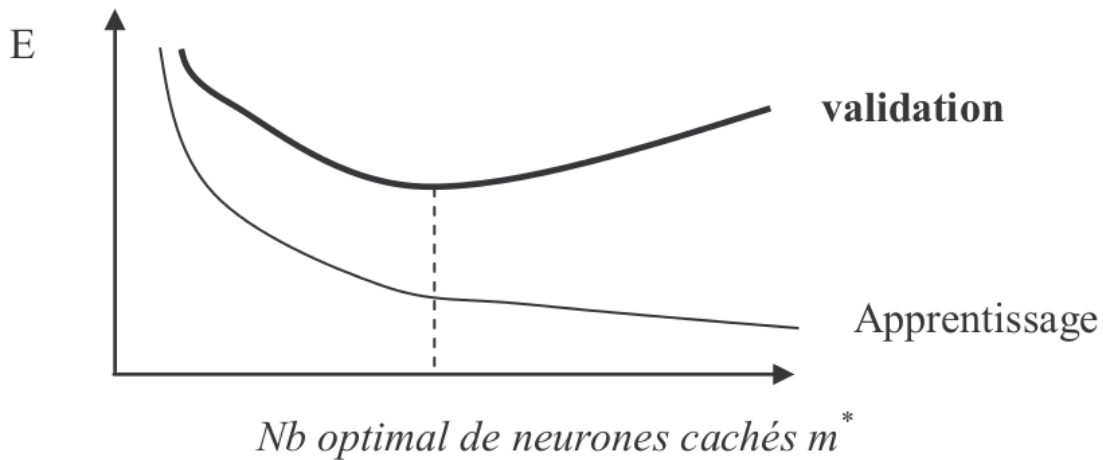


FIGURE 3.14 Évolution de l'erreur en fonction du nombre de neurones cachés

recherche de modèles bien ajustés [5].

### 3.3.6 Techniques de régularisation

Les méthodes de régularisation ne cherchent pas à limiter la complexité du réseau, mais contrôlent la valeur des poids pendant l'apprentissage. Il devient possible d'utiliser des modèles avec un nombre élevé de poids et donc un modèle complexe, même si le nombre d'exemples d'apprentissage est faible. Bartlett [5] a montré que la valeur des poids était plus importante que leur nombre afin d'obtenir des modèles qui ne sont pas surajustés. Il montre que si un grand réseau est utilisé et que l'algorithme d'apprentissage trouve une erreur quadratique moyenne faible avec des poids de valeurs absolues faibles, alors les performances en généralisation dépendent de la valeur des poids plutôt que de leur nombre. Plusieurs méthodes de régularisation existent dans la littérature, nous allons présenter la régularisation par modération des poids et la régularisation bayésienne.

#### 3.3.6.1 Régularisation par modération des poids

La technique de régularisation par pénalisation ajoute un terme de pénalité  $E_w$  à la fonction de coût classique  $E_D$  (Equation 3.2) afin de favoriser les fonctions régulières. La fonction à minimiser  $E_T$  est alors de la forme :

$$E_T = E_D + \mu E_w \quad (3.3)$$

où  $\mu$  est un coefficient de régularisation ou hyperparamètre dont la valeur doit satisfaire le compromis biais-variance [7] et [63]. Il s'organise comme suit :

- si  $\mu$  est trop grand, la minimisation tend à faire diminuer les valeurs des paramètres sans tenir compte des données de la base d'apprentissage ;
- à l'inverse, si  $\mu$  est trop petit, le terme de régularisation a très peu d'effet sur l'apprentissage, donc le surajustement risque d'apparaître ;
- dans le cas intermédiaire, les poids ont des valeurs modérées après l'apprentissage.

La fonction de pénalité  $E_w$  la plus largement utilisée est celle qui pénalise les modèles ayant des valeurs de paramètres élevées. Dans ce cas, on parle de régularisation par modération des poids ou weight decay. Elle s'exprime ainsi :

$$E_w = \frac{1}{2} \sum_{i=1}^p w_i^2 \quad (3.4)$$

où  $p$  est le nombre de paramètres du réseau.

La méthode weight decay a pour objectif d'empêcher les paramètres de prendre des valeurs exagérées, en minimisant, pendant l'apprentissage, la fonction de coût  $E_T$  qui devient :

$$E_T = E_D + \frac{\mu}{2} \sum_{i=1}^p w_i^2 \quad (3.5)$$

Cette méthode présente l'avantage d'être facile à mettre en œuvre, puisque le gradient de  $E_T$  se calcule très simplement à partir du gradient de  $E_D$  et du vecteur des poids du réseau  $w$ . Il suffit d'ajouter la quantité  $\mu w$  au vecteur gradient  $\nabla E_D$  calculé par l'algorithme de rétropropagation.

$$\nabla E_T = \nabla E_D + \mu w \quad (3.6)$$

Cependant, l'identification de la valeur optimale de l'hyperparamètre  $\mu$  doit être faite par validation croisée. Or, elle a un coût de calcul important. Pour contourner ce problème, MacKay [62] propose d'utiliser une approche probabiliste appelée régularisation bayésienne durant la procédure d'apprentissage pour contrôler automatiquement la complexité du RNA.

### 3.3.7 Régularisation bayésienne

L'approche bayésienne [62] est une alternative aux méthodes traditionnelles. Elle propose un cadre rigoureux pour formaliser des croyances a priori et déterminer comment celles-ci doivent être mises à jour une fois les données observées. Dans un contexte d'ap-

prentissage où l'objectif est d'estimer les paramètres  $w$  d'un modèle, la démarche bayésienne requiert d'abord d'exprimer sous forme de distribution de probabilités les connaissances a priori  $p(w)$  concernant les valeurs envisageables des paramètres.

Une fois les données d'apprentissage prises en compte, cette probabilité a priori est transformée en probabilité a posteriori grâce au théorème de Bayes :

$$P(w|D) = \frac{p(D|w)p(w)}{p(D)} \quad (3.7)$$

où  $D$  représente l'ensemble des données d'apprentissage,  $p(w)$  la densité de probabilité a priori des poids,  $p(D|w)$  la densité de probabilité d'observer les données connaissant les poids du réseau, et  $P(w|D)$  la probabilité a posteriori que l'on cherche à déterminer.

La régularisation bayésienne appliquée aux RNA est fondée sur la maximisation de la densité de probabilité a posteriori des paramètres du réseau de neurones en prenant en compte la base d'apprentissage. Contrairement à la méthode de validation simple, cette méthode ne requiert ni l'utilisation d'une base de validation ni l'apprentissage systématique de RNA de différentes tailles. Elle comporte deux étapes à savoir l'estimation des poids et des biais du RNA par le théorème de Bayes et l'ajustement des hyperparamètres  $\alpha$  et  $\beta$  de régularisation pour une bonne capacité de généralisation.

### 3.3.7.1 Estimation des poids et des biais

La densité de probabilité liée aux données d'apprentissage  $p(D|w, \beta)$  est représentée par une gaussienne. C'est la fonction de vraisemblance ou likelihood. Elle s'exprime ainsi :

$$p(D|w, \beta) = \frac{1}{Z_D(\beta)} \exp(-\beta E_D) \quad (3.8)$$

$$Z_D(\beta) = \left(\frac{2\pi}{\beta}\right)^{\frac{N}{2}} \quad (3.9)$$

$\beta$  est un hyperparamètre représentatif de l'écart type de l'erreur. Il est égal à l'inverse de la variance du bruit de la sortie prévue. La section 3.3.7.2 présente la méthode de calcul de sa valeur optimale.  $Z_D$  est le facteur de normalisation du bruit blanc gaussien. On suppose que la densité de probabilité des paramètres  $w$  a priori, c'est-à-dire avant présentation des données de la base d'apprentissage au RNA, est gaussienne, blanche et centrée. Cette hypothèse sur la distribution des paramètres internes du réseau est fondée sur le fait que les poids et

les biais peuvent être positifs ou négatifs et que pour obtenir une bonne généralisation en favorisant les variations « douces » de la fonction d'approximation, il est préférable que la valeur de ces paramètres soit faible. La densité de probabilité des paramètres  $w$  a priori s'exprime ainsi :

$$p(w|\alpha) = \frac{1}{Z_w(\alpha)} e^{(-\alpha \cdot E_w)} \quad (3.10)$$

$$Z_w = \left(\frac{2\pi}{\alpha}\right)^{\frac{p}{2}}, \quad (3.11)$$

$\alpha$  représente l'inverse de la variance des poids et biais. Comme il contrôle la distribution des autres paramètres donc  $\alpha$  est un hyperparamètre.  $Z_w$  est la constante de normalisation de la fonction de densité de probabilité.

$$E_w = \frac{1}{2} \sum_{i=1}^p w_i^2 \quad (3.12)$$

où  $n$  désigne le nombre de paramètres internes  $w_k$  du RNA (poids et biais).

La densité de probabilité a posteriori du vecteur de paramètres  $w$  est donnée par :

$$p(w|D, \alpha, \beta) = \frac{p(D|w, \beta)p(w|\alpha)}{p(D|\alpha, \beta)} \quad (3.13)$$

En utilisant les équations (3.8) et (3.10) dans l'équation (3.13), on obtient finalement :

$$p(w|D, \alpha, \beta) = \frac{1}{Z_F(\alpha, \beta)} \exp(-(\beta E_D + \alpha E_w)) \quad (3.14)$$

où

$$Z_F = Z_w(\alpha)Z_D(\beta)P(D|\alpha, \beta) \quad (3.15)$$

$Z_F$  est le facteur de normalisation. Cependant, dans le contexte de l'apprentissage neuronal où les paramètres sont nombreux ( $p \gg 10$ ), le calcul analytique de  $Z_F$  est impossible. Pour rendre cette intégrale analytiquement réalisable, MacKay propose une approximation gaussienne de la distribution a posteriori des poids. La seule inconnue  $Z_F$  de cette égalité est déterminée en faisant un développement limité de  $P(w/D, \alpha, \beta)$  autour de la solution  $w_{MP}$  de  $w$  au sens du maximum a posteriori obtenu lors de la minimisation de  $E_t$ . Cela conduit

à :

$$Z_F = (2\pi)^{\frac{p}{2}} \times |\mathbf{H}^{MP}|^{-\frac{1}{2}} \times \exp(-E_T(w_{MP})) \quad (3.16)$$

avec  $\mathbf{H}$  la matrice Hessienne de la fonction d'erreur régularisée calculée pour  $w_{MP}$ .

Les paramètres internes optimaux sont ceux qui maximisent la densité de probabilité a posteriori  $P(w/D, \alpha, \beta)$ . On remarque dans l'équation (3.14) que la maximisation de cette densité de probabilité a posteriori des paramètres est équivalente à minimiser la fonction objectif régularisée  $E_T$  donnée par :

$$\begin{aligned} E_T &= \beta E_D + \alpha E_w \\ &= \frac{\beta}{2} \sum_{i=1}^p (y_i(w) - t_i)^2 + \frac{\alpha}{2} \sum_{i=1}^n w_i^2 \end{aligned} \quad (3.17)$$

Le premier terme  $E_D$  de l'équation (3.17) est proportionnel à l'erreur quadratique moyenne entre la sortie du RNA et celle de la base d'apprentissage. C'est la fonction d'erreur habituellement utilisée pour l'apprentissage des RNA. Le deuxième terme  $E_w$  est un terme de régularisation. Si le terme de régularisation est petit, c'est-à-dire si l'amplitude des paramètres du RNA est faible, alors cela conduit à un RNA dont la sortie varie de manière douce s'opposant au phénomène de sur-paramétrisation. Comme l'a précisé Bishop [7], en plus d'être un facteur multiplicatif,  $E_T$  correspond à la somme des carrés des erreurs avec le terme de régularisation par modération des poids qui dépend uniquement du ratio  $\mu = \frac{\alpha}{\beta}$ . On remarque que l'approche bayésienne mène automatiquement et naturellement à une fonction régularisée à minimiser.

### 3.3.7.2 Optimisation bayésienne des hyperparamètres $\alpha$ et $\beta$

Les hyperparamètres  $\alpha$  et  $\beta$  contrôlent la complexité du modèle neuronal. Si  $\alpha \ll \beta$ , l'apprentissage sera facile mais la généralisation risque d'être mauvaise. Par contre, si  $\alpha \gg \beta$  alors les paramètres du réseau sont très faibles et ne permettent pas un bon apprentissage. Il faut donc faire un compromis entre les valeurs de  $\alpha$  et  $\beta$ .

MacKay propose l'approche evidence framework. Elle consiste à trouver les valeurs optimales des hyperparamètres notés  $\alpha_{MP}$  et  $\beta_{MP}$  et de faire les calculs restants avec ces valeurs optimales. Une fois de plus, le théorème de Bayes permet de déduire les valeurs

optimales des hyperparamètres à partir des données  $D$ .

$$p(\alpha, \beta/D) = \frac{p(D/\alpha, \beta)p(\alpha, \beta/M_i)}{p(D/M_i)} \quad (3.18)$$

où  $p(\alpha, \beta)$  sont les hyperparamètres a priori et  $p(D|\alpha, \beta)$  est le terme de probabilité intitulé evidence de  $\alpha$  et  $\beta$ . Comme il n'y a pas d'idée a priori sur les valeurs des hyperparamètres,  $p(\alpha, \beta)$  sont pris comme une distribution uniforme. De plus, comme le facteur de normalisation  $p(D)$  est indépendant de  $\alpha$  et  $\beta$ , maximiser la probabilité a posteriori  $p(\alpha, \beta|D)$  revient à maximiser le terme  $p(D|\alpha, \beta)$ .

Supposons  $p(\alpha, \beta|M_i)$ , la densité de probabilité a priori de  $\alpha$  et  $\beta$ , uniforme. Par conséquent, maximiser  $p(\alpha, \beta/D)$  est équivalent à maximiser  $p(D|\alpha, \beta)$  d'après les équations (3.15) et (3.18).

$$\begin{aligned} p(D|\alpha, \beta) &= \frac{Z_F(\alpha, \beta)}{Z_W(\alpha)Z_D(\beta)} \\ &= \frac{(2\pi)^{\frac{p}{2}} \times |\mathbf{H}_{MP}|^{-\frac{1}{2}} \times \exp(-E_T(w_{MP}))}{\left(\frac{2\pi}{\alpha}\right)^{\frac{p}{2}} \cdot \left(\frac{2\pi}{\beta}\right)^{\frac{N}{2}}} \end{aligned} \quad (3.19)$$

Les valeurs optimales  $\alpha_{MP}$  et  $\beta_{MP}$  correspondent au maximum de l'evidence de  $\alpha$  et  $\beta$ . Comme nous l'avons vu ci-avant, la fonction de densité de probabilité peut être interprétée comme une fonction d'erreur à minimiser en prenant le logarithme de l'équation (3.19) comme suit :

$$\log p(D|\alpha, \beta) = -\alpha E_w^{MP} - \beta E_D^{MP} - \frac{1}{2} \log |\mathbf{H}| + \frac{p}{2} \log \alpha + \frac{N}{2} \log \beta - \frac{N}{2} \log(2\pi) \quad (3.20)$$

Les valeurs optimales des hyperparamètres sont alors obtenues en dérivant 3.20. Les détails des calculs sont disponibles dans [7].

Les solutions  $\alpha_{MP}$  et  $\beta_{MP}$  de  $\alpha$  et  $\beta$  maximisant  $p(D|\alpha, \beta)$  sont obtenues en dérivant le logarithme de  $p(D/\alpha, \beta)$  par rapport à  $\alpha$  et  $\beta$ . On obtient :

$$\alpha_{MP} = \frac{\gamma}{2E_w(w_{MP})} \quad (3.21)$$



$$\beta_{MP} = \frac{N_D - \gamma}{2E_D(w_{MP})} \quad (3.22)$$

Avec  $\gamma$  le nombre de paramètres effectifs influant sur la sortie du RNA.

$$\gamma = \sum_{k=1}^m \frac{\lambda_k}{\lambda_k + \alpha} \quad (3.23)$$

où  $\alpha_k$  sont les valeurs propres de la matrice hessienne des erreurs irrégulières  $E_D$  c'est-à-dire  $\mathbf{H} = \beta \nabla \nabla E_D$ .

L'apprentissage du RNA est effectué en ajustant  $w$ ,  $\alpha$  et  $\beta$  à chaque itération de l'algorithme d'apprentissage.

### 3.3.8 Mise en oeuvre du modèle neuronal

Le modèle neuronal retenu pour le post-traitement de la prévision numérique du GHI réalise une correction par modélisation du biais. Ainsi, la sortie du modèle neuronal est le biais de la prévision faite par le modèle WRF.

L'architecture MLP, avec la fonction tangente hyperbolique comme fonction d'activation des neurones, est utilisée. Le choix des entrées pertinentes est fait durant la phase de sélection. Il s'ensuit une gestion de la complexité du modèle neuronal avec l'implémentation de l'approche evidence.

#### 3.3.8.1 Sélection des entrées

La méthode Automatic Relevance Determination ou ARD est utilisée pour choisir les entrées pertinentes. Elle consiste à assigner un coefficient de régularisation unique à chaque entrée. Plus précisément, tous les poids associés à une entrée sont contrôlés par le même hyperparamètre  $\alpha_g$ . Cet hyperparamètre est relié à la gaussienne a priori avec une moyenne nulle et une variance de  $\frac{1}{\alpha_g}$ . A la fin de la phase d'apprentissage, les poids avec un  $\alpha_g$  élevé (ou inversement une petite variance  $\frac{1}{\alpha_g}$ ) sont proches de zéro. Par conséquent, l'entrée correspondante n'est pas pertinente et est éliminée.

A la suite de l'application de la méthode ARD, l'indice de ciel clair  $\widehat{k}_t^*$  prévu par le modèle numérique WRF et le cosinus de l'angle solaire zénithal  $\cos(SZA)$  sont retenus comme entrées pertinentes du modèle neuronal. La figure 3.15 synthétise les entrées et sorties du modèle neuronal mis en place.




FIGURE 3.15 Entrées et sorties du modèle neuronal.

### 3.3.8.2 Implémentation de l'approche evidence framework

Pour implémenter l'approche evidence framework, c'est-à-dire trouver les valeurs optimales des poids  $w_{MP}$  et des hyperparamètres  $\alpha$  et  $\beta$ , un traitement itératif est appliqué. Les enchaînements des itérations se présentent comme suit :

1. Choisir les valeurs initiales des hyperparamètres  $\alpha$  et  $\beta$  petites. Ensuite, initialiser les poids du réseau avec les valeurs tirées de la loi de probabilité a priori. A la  $i$ -ème itération, étant donné l'estimation courante des poids  $w_i$  et des hyperparamètres  $\alpha_i$  et  $\beta_i$ , l'estimation courante de  $E_T^{(i)}$  (Equation 3.17) peut être calculée.
2. Trouver les poids  $w_{MP}^{(i+1)}$  qui minimise  $E_T^{(i)}$  en utilisant un algorithme d'apprentissage non-linéaire standard tel que l'algorithme de Gauss-Newton ou la méthode des gradients conjugués. Ensuite calculer  $E_w^{(i+1)}$  et  $E_D^{(i+1)}$ .
3. Calculer les nouvelles valeurs de  $\alpha^{(i+1)}$  et  $\beta^{(i+1)}$  de l'itération  $(i+1)$  à partir des trois étapes suivantes :

- (a)  $\gamma^{(i+1)} = \sum_{k=1}^m \frac{\lambda_k}{\lambda_k + \alpha^{(i)}}$  où  $\lambda_k$  est le  $k$ -ième valeur propre de la matrice hessienne c'est-à-dire  $\beta^{(i)} \nabla \nabla E_D^{(i+1)}$
- (b)  $\alpha^{(i+1)} = \frac{\gamma^{(i+1)}}{2 \cdot E_w^{(i+1)}}$
- (c)  $\beta^{(i+1)} = \frac{N - \gamma^{(i+1)}}{2 \cdot E_D^{(i+1)}}$

4. Reprendre l'itération à partir de l'étape 2 en utilisant les paramètres  $w^{(i+1)}$ ,  $\alpha^{(i+1)}$  et  $\beta^{(i+1)}$  pour calculer les nouvelles valeurs des paramètres.

Étant donné les valeurs initiales de  $\alpha$ , c'est une bonne pratique de démarrer avec des valeurs relativement petites afin de laisser au modèle suffisamment de flexibilité pour s'ajuster aux données.

La convergence de la procédure se produit lorsque l'erreur de régularisation (Equation 3.17) est égale à la moitié du nombre de données utilisées. En effet, la théorie stipule que  $E_T = \frac{N}{2}$  quand  $\alpha = \alpha_{MP}$  et  $\beta = \beta_{MP}$ .

### **3.4 Conclusion**

Le modèle numérique WRF et le modèle neuronal bayésien développés pour faire de la prévision du GHI à l'horizon J+1 sont présentés. Dans un premier temps, la configuration de WRF s'est intéressée à la résolution spatiale et à la résolution temporelle pertinentes à appliquer. Ensuite il a été question d'identifier les paramètres physiques à appliquer dans le contexte de milieu insulaire de La Réunion. Les ressources nécessaires au bon fonctionnement du modèle WRF sont également présentés.

Dans un deuxième temps, la méthode appliquée pour concevoir le modèle neuronal bayésien est présentée. La gestion de la complexité du modèle à travers l'optimisation des hyperparamètres avec la régularisation bayésienne est également présentée.

# Chapitre 4

## Prévision du rayonnement global à très court terme (t+h)

### Sommaire

---

<b>4.1</b>	<b>Introduction</b>	<b>70</b>
<b>4.2</b>	<b>Présentation générale de la méthode</b>	<b>70</b>
<b>4.3</b>	<b>Justification du modèle retenu</b>	<b>72</b>
<b>4.4</b>	<b>Modèle hybride de Kalman</b>	<b>73</b>
4.4.1	Algorithme	73
4.4.2	Initialisation des variables	75
4.4.3	Calibration du modèle	76
4.4.4	Identification des entrées pertinentes	78
4.4.4.1	Modèle de Pelland : entrées de rayonnement à l'ordre 1	80
4.4.4.2	Modulation de l'ordre des entrées en rayonnement	81
4.4.4.3	Entrées additionnelles : variables atmosphériques	81
4.4.4.4	Indice de ciel clair	83
4.4.4.5	Indice de ciel clair et variables atmosphériques supplémentaires	84
4.4.4.6	Synthèse des résultats	85
<b>4.5</b>	<b>Conclusion</b>	<b>86</b>

---

## 4.1 Introduction

La recherche appliquée pour mettre en place le modèle hybride de Kalman qui produit une prévision multi-horizon du rayonnement solaire global est détaillée dans ce chapitre. Elle est axée sur une étude de la performance du modèle en fonction des valeurs d'initialisation et des paramètres d'entrées. Cette étude est fondée sur des données mesurées et calculées durant une année sur le site de Saint-Pierre.

Après une présentation générale de la méthode proposée, nous expliquerons le choix d'hybrider la prévision numérique du modèle WRF avec les mesures pyranométriques réalisées sur le site d'expérimentation et la position du soleil. La dernière partie décrit la mise en œuvre du modèle hybride en terme d'algorithme, d'initialisation, de calibration et de sélection des entrées.

## 4.2 Présentation générale de la méthode

La méthode de prévision à très court terme proposée dans ces travaux est un modèle hybride. En effet, elle combine dans un modèle statistique, à savoir le filtre de Kalman linéaire<sup>1</sup>, les sorties d'un modèle numérique de prévision, les mesures pyranométriques faites sur le site d'expérimentation et le cosinus de l'angle solaire zénithal.

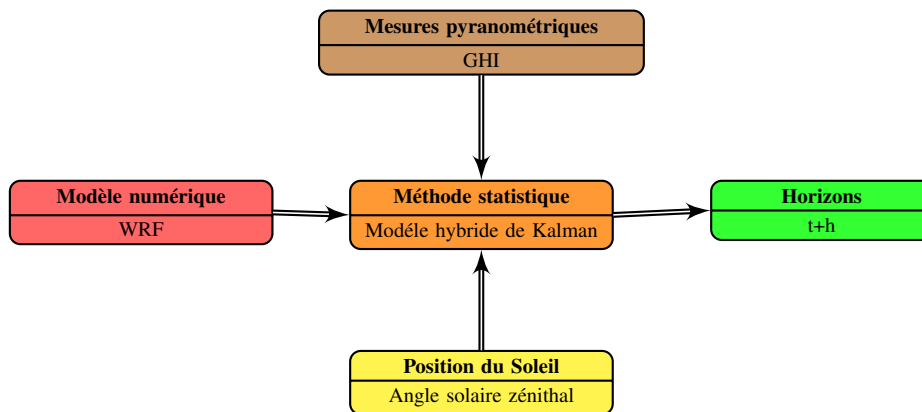


FIGURE 4.1 Vue globale de la démarche de prévision à l'horizon t+h

La Figure 4.1 illustre la vue globale de la méthode proposée. Son choix est explicité dans la section 4.3. Le modèle hybride fournit une prévision à l'horizon t+ h avec h qui varie entre 5 minutes et 3 heures. Deux variantes du modèle ont été développées pour faire des prévisions à différents horizons temporels.

1. Le filtre de Kalman linéaire est présenté en détail dans l'Annexe A

La première variante, détaillée dans la section 4.4, est une méthode (prévision) énergétique. En effet, elle réalise la prévision de la valeur moyenne du rayonnement solaire sur une période qui varie en fonction de l'horizon considéré. Comme la moyenne est proportionnelle à l'énergie solaire incidente de la période considérée (entre  $t$  et  $t+h$ ), la méthode est appelée modèle hybride de prévision énergétique. La taille de l'horizon de prévision est définie par la fréquence d'échantillonnage de la mesure pyranométrique. Dans ce contexte, les mesures pyranométriques historiques sont moyennées sur plusieurs pas de temps allant de 5 minutes à 3 heures. La Figure 4.2 illustre la technique de production de l'horizon de prévision du modèle hybride de prévision énergétique. L'objectif de cette procédure est de produire la prévision de l'énergie sur plusieurs horizons.

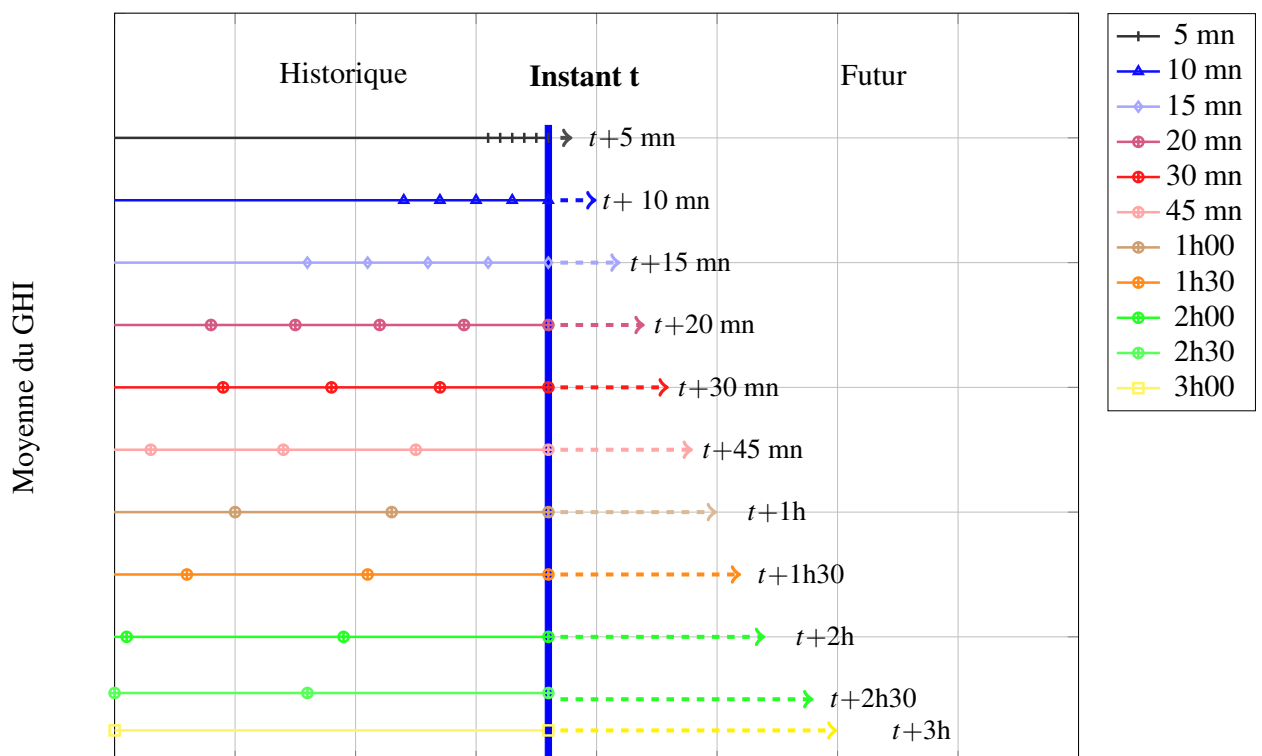


FIGURE 4.2 Horizons du modèle hybride de prévision énergétique

La deuxième variante de la méthode hybride de Kalman, décrite à la section 4.4, réalise une prévision du rayonnement solaire à l'instant  $t+h$ . En effet, elle produit plusieurs horizons de prévision à partir de la mesure pyranométrique de l'instant  $t$  et des prévisions numériques fournies par le modèle WRF. Ainsi, la mesure pyranométrique et les prévisions numériques sont traitées par le modèle hybride de prévision du rayonnement pour produire des prévisions avec des horizons allant de 5 minutes à 3 heures. La Figure 4.3 illustre le principe de

fonctionnement avec l'exemple du calcul fait à 11h00 am pour réaliser les prévisions allant de 11h05 à 14h00 .

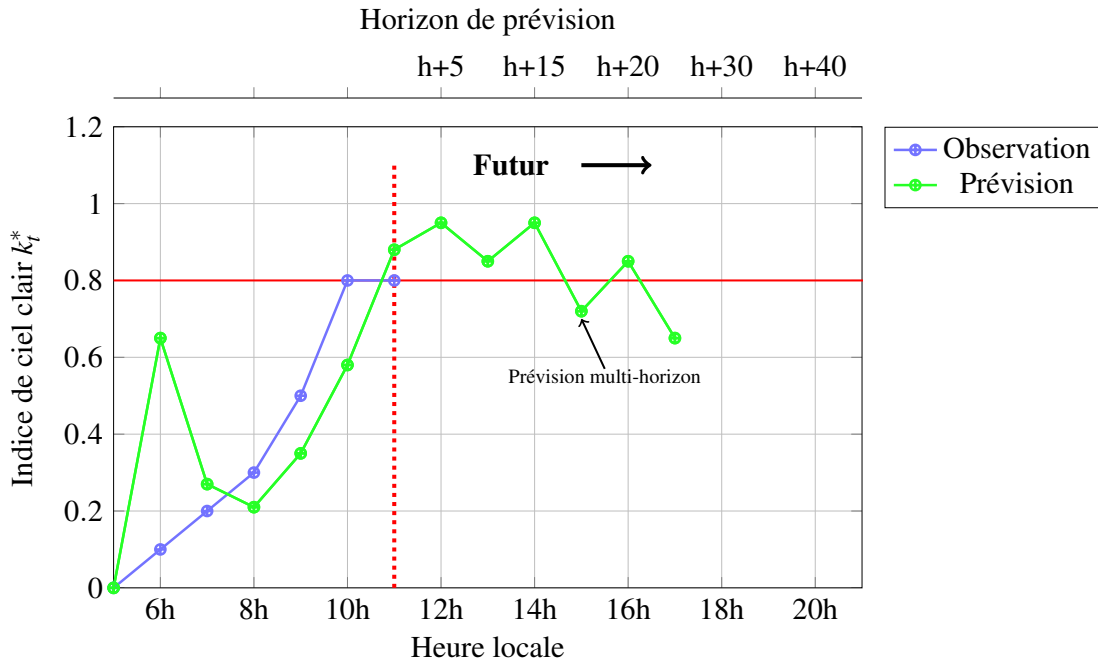


FIGURE 4.3 Principe de fonctionnement du modèle de prévision multihorizon.

A la suite de la présentation générale faite sur la vue globale de la méthode et des horizons de prévision disponibles, les arguments expliquant le choix du modèle hybride de Kalman sont détaillés ci-après.

### 4.3 Justification du modèle retenu

L'objectif étant de fournir aux gestionnaires de réseaux et aux producteurs des outils fonctionnels, le choix s'est porté sur le filtre de Kalman. En effet, une étude bibliographique ([77] et [25]) a montré que le filtre de Kalman est une technique de post-traitement statistique performante dans le domaine de la prévision de variables météorologiques (vent, température, GHI, ...). Par ailleurs, le caractère récursif de l'algorithme de Kalman, à la différence des autres méthodes classiques de prévision, tel que le modèle classique ARMA, en fait une solution naturellement adaptée à un fonctionnement opérationnel.

La puissance de calcul nécessaire pour exécuter le programme est très faible. En effet, les traitements sont faits sur un ordinateur de bureau et les résultats sont disponibles rapidement.

Le programme demande une faible puissance de calcul et permet d'avoir des résultats en temps réel.

## 4.4 Modèle hybride de Kalman

Le modèle hybride de Kalman réalise la prévision du biais sur l'indice de ciel clair susceptible de se produire avec la prévision du modèle numérique. La genèse de l'idée du modèle hybride s'est faite en deux parties. D'abord, les travaux de Pelland [77] ont été testés. Il s'agit de l'application du filtre de Kalman aux mesures historiques pour corriger la prévision du modèle numérique GEM<sup>2</sup>. Ensuite, la technique d'initialisation des paramètres s'est inspirée des travaux de Galanis [25] qui utilise le filtre de Kalman pour la prévision du vent. L'investigation de plusieurs variantes de l'approche de Pelland combinée à la technique d'initialisation de Galanis a donné lieu à une nouvelle méthode de prévision hybride. Cette dernière s'appuie sur le principe du filtre de Kalman linéaire décrit dans l'Annexe A.

### 4.4.1 Algorithme

Les entrées et la sortie du modèle hybride sont présentées dans la Figure 4.4.

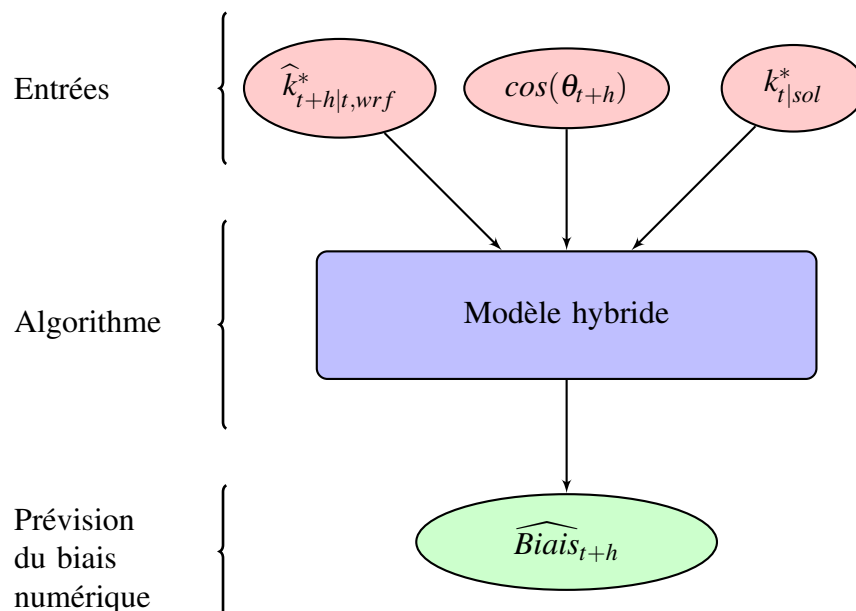


FIGURE 4.4 Entrées et sortie du modèle hybride de Kalman

2. GEM pour Global Environmental Multi échelle est un modèle numérique canadien



Dans cette illustration, la variable  $\widehat{k}_{t+h|t,wrf}^*$  représente l'indice de ciel clair prédit à l'instant  $t$  par le modèle WRF pour l'horizon  $t+h$ . La variable  $k_{t|sol}^*$  est l'indice de ciel clair mesuré à l'instant  $t$  et la variable  $\cos(\theta_{t+h})$  est le cosinus de l'angle solaire zénithal calculé pour l'instant  $t+h$ . Certaines de ces variables d'entrées, à savoir  $k_{t+h|t,wrf}^*$  et  $\cos(\theta_{t+h})$ , composent la matrice de mesure  $\mathbb{H}_{t+h}$  décrite par l'équation (4.1).

$$\mathbb{H}_{t+h} = \begin{bmatrix} 1 & \widehat{k}_{t+h|t,wrf}^* & \cos(\theta_{t+h}) \end{bmatrix} \quad (4.1)$$

D'après l'algorithme du filtre de Kalman présenté en détail dans l'Annexe A, la variable de mesure  $y_t$  est une combinaison linéaire de la matrice de mesure  $\mathbb{H}_t$  et du vecteur d'état  $x_t$ . De cette définition est déduite  $\widehat{Biais}_{t+h|t}$ , la prévision du biais de  $y_t$  pour l'horizon  $t+h$ . L'équation (4.2) présente l'expression de  $\widehat{Biais}_{t+h|t}$ .

$$\widehat{Biais}_{t+h|t} = \mathbb{H}_{t+h} \cdot \widehat{x}_{t+h|t} \quad (4.2)$$

La variable  $\widehat{x}_{t+h|t}$  représente le vecteur d'état prédit à l'instant  $t$  par le filtre de Kalman pour l'horizon  $t+h$ . La nouvelle prévision de l'indice de ciel clair,  $\widehat{k}_{t+h|t}^*$ , est le résultat de la correction faite avec le biais prédit. Elle est exprimée par l'équation (4.3) comme suit :

$$\widehat{k}_{t+h|t}^* = \widehat{k}_{t+h|t,wrf}^* - \widehat{Biais}_{t+h|t} \quad (4.3)$$

L'enchaînement des phases de prédiction et de correction, ainsi que les variables et les équations appliquées, sont synthétisés dans la Figure 4.5.

La variable  $B_t$  représente la matrice de covariance de l'erreur,  $Q_t$  est la covariance du bruit sur l'état,  $R_t$  est la covariance du bruit sur les mesures et  $K_t$  est le gain du filtre de Kalman. Les originalités de l'algorithme par rapport à la méthode de Pelland sont coloriées en vert. Les détails de la technique appliquée pour les identifier sont explicités dans la section 4.4.4.

La prévision du biais est réalisée de manière opérationnelle. En effet, une comparaison des prévisions du modèle hybride et des mesures pyranométriques sur site est faite pour chaque instant  $t$ . Cette procédure permet de faire des corrections avant de produire la prévision de l'instant  $t+h$ . Le démarrage de l'algorithme passe par une phase d'initialisation des variables qui est l'objet de la section suivante.

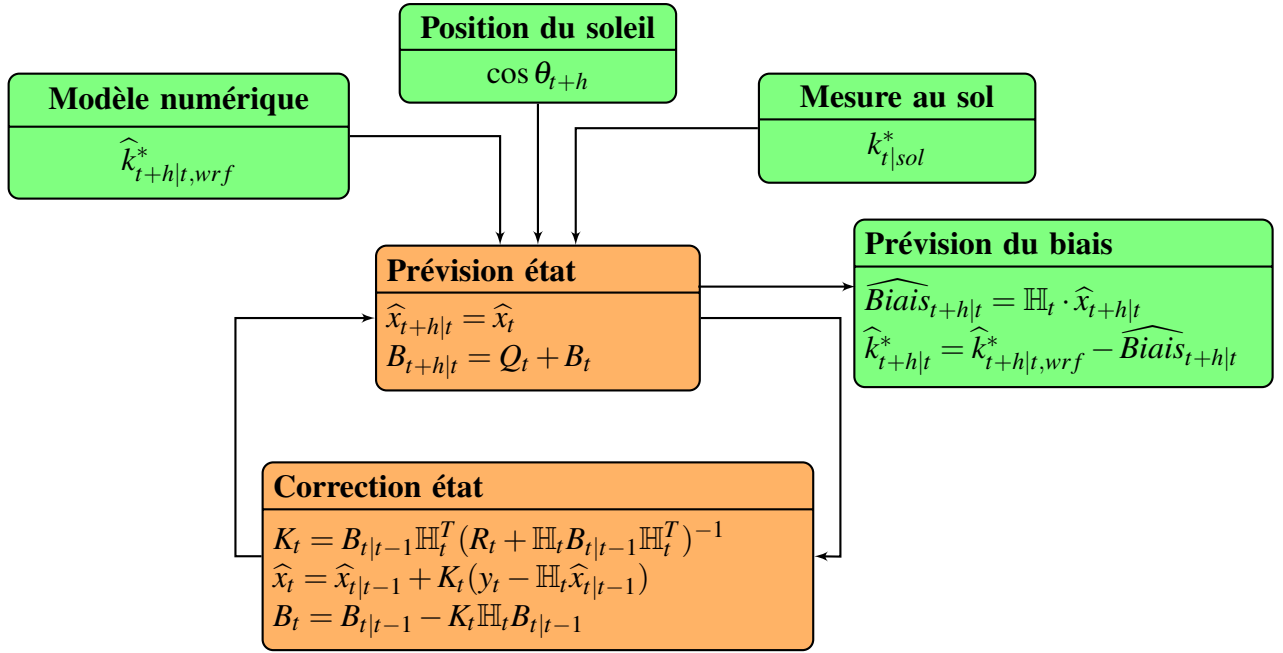



FIGURE 4.5 Algorithme de la méthode hybride.

#### 4.4.2 Initialisation des variables

Le choix des données initiales du modèle hybride de Kalman est inspiré des travaux de Galanis [25]. Dans ce contexte, le vecteur d'état initial  $x_0$  est initialisé à zéro. Avec l'hypothèse selon laquelle les variables d'état ne sont pas corrélées, la matrice de covariance initiale  $B_0$  est définie diagonale. De plus, les termes de la diagonale sont fixés à des valeurs élevées. Cela indique au filtre de Kalman qu'il ne doit pas accorder beaucoup d'importance aux valeurs initiales.

Pour identifier les valeurs initiales optimales de  $Q_t$  et  $R_t$ , notées respectivement  $Q_0$  et  $R_0$ , une série de leurs combinaisons a été testée. Ainsi sont créées plusieurs valeurs de  $Q_0$  et  $R_0$ , qui varient respectivement avec une échelle logarithmique allant de  $10^{-8}$  à  $10^{-3}$ . Cette série de valeurs représente 100 combinaisons possibles de  $Q_0$  et  $R_0$ . Elles sont testées sur une année de prévisions numériques. Par ailleurs, les variables  $Q_t$  et  $R_t$  sont fixées respectivement à la valeur courante de  $Q_0$  et  $R_0$  durant toutes ces simulations. La combinaison de  $Q_0$  et  $R_0$  produisant la plus faible RMSE est retenue comme valeurs initiales optimales. L'utilisation du RMSE relatif comme critère de sélection est justifiée à la section 4.4.4.

La Figure 4.6 illustre l'évolution de la valeur relative du RMSE et du MBE en fonction de  $Q_0$  et  $R_0$ . Cette représentation graphique montre une corrélation marquée entre les valeurs de  $Q_0$  et  $R_0$ . Cependant, le RMSE relatif minimal est observé avec une unique combinaison

FIGURE 4.6 Évolution des erreurs en fonction de  $Q_0$  et  $R_0$ 

de  $Q_0$  et  $R_0$ . Ce résultat est valable aussi bien pour le RMSE que pour le MBE. Le vecteur d'état initial  $x_0$  et la matrice de covariance initiale  $B_0$  utilisée dans l'algorithme sont choisis comme suit :

$$\begin{aligned}
 x_0 &= \begin{bmatrix} 0 & 0 & 0 \end{bmatrix} \\
 B_0 &= \begin{bmatrix} 5 & 0 & 0 \\ 0 & 5 & 0 \\ 0 & 0 & 5 \end{bmatrix}
 \end{aligned} \tag{4.4}$$

Une fois les valeurs initiales optimales  $Q_0$  et  $R_0$  identifiées, l'étape suivante consiste à définir leurs politiques d'évolution durant la phase de calibration. Concernant les variables  $x_t$ ,  $B_t$  et  $y_t$ , leur évolution est réalisée par l'algorithme du modèle hybride.

### 4.4.3 Calibration du modèle

Dans l'optique de définir la procédure optimale d'évolution de  $Q_t$  et  $R_t$ , la technique de la fenêtre glissante est testée. Le principe de fonctionnement repose sur la taille  $T$  d'une fenêtre glissante utilisée pour leur estimation. Cette dernière représente le nombre optimal de données historiques à utiliser pour calculer le  $Q_t$  et le  $R_t$  de chaque instant  $t$ .

Pour trouver la longueur optimale de  $T$ , une variation de sa largeur de 1 à 100 mesures historiques est testée. Ainsi, les covariances  $Q_t$  et  $R_t$  sont recalculées avec  $T$  mesures précédentes pour chaque test. Cette méthode est évaluée sur une année de données du GHI. La

Figure 4.7 représente d'une part la variation du RMSE relatif en fonction de la taille de la fenêtre utilisée pour recalculer  $Q_t$  et  $R_t$  (trait continu). De l'autre, elle présente le RMSE relatif observé lorsque  $Q_t$  et  $R_t$  sont constantes et égales à leurs valeurs initiales respectives (trait pointillé).

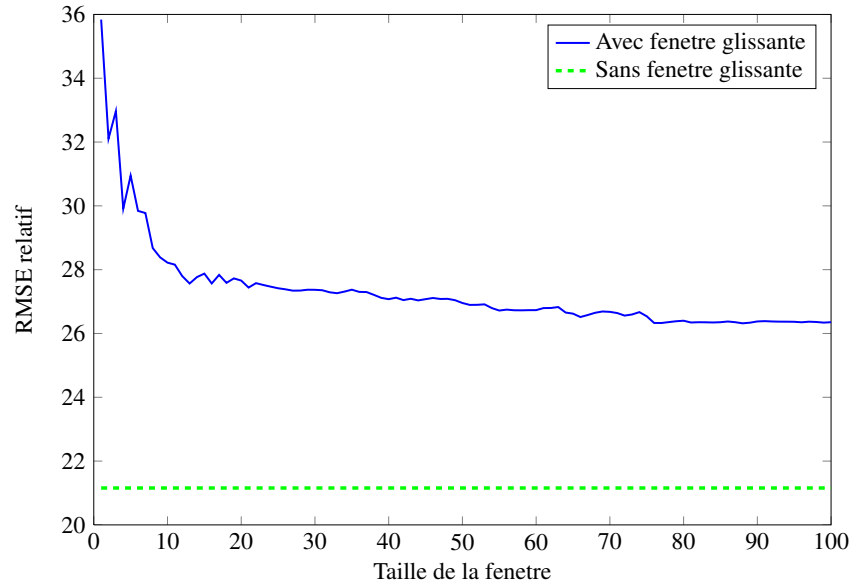


FIGURE 4.7 Variation du RMSE avec ou sans fenêtre glissante.

Lorsqu'une fenêtre glissante est appliquée, une amélioration de la qualité de la prévision est observée avec l'accroissement de la valeur de  $T$ . En effet, le RMSE relatif tend vers une asymptote de 26%. Cependant, ce résultat ne permet pas d'améliorer la qualité de la méthode de prévision. En effet, le RMSE relatif est inférieur à 22% lorsque  $Q_t$  et  $R_t$  sont maintenues constantes et égales à leurs valeurs initiales optimales respectives  $Q_0$  et  $R_0$ .

La représentation graphique de la trace de  $B_t$  lorsque  $Q_t$  et  $R_t$  sont maintenues constantes, avec la Figure 4.8, montre que l'algorithme converge très rapidement. Par conséquent, la suite des calculs du modèle hybride de Kalman applique le maintien des valeurs initiales optimales de la covariance du bruit sur l'état  $Q_t$  et de la covariance du bruit sur les mesures  $R_t$ . La solution retenue est résumée par l'équation (4.5).

$$\begin{aligned} Q_t &= Q_0 \\ R_t &= R_0 \end{aligned} \quad (4.5)$$

La description de la méthode hybride de Kalman se poursuit à travers la présentation de la méthode appliquée pour identifier les entrées pertinentes.




FIGURE 4.8 Trace de la matrice de covariance  $B_t$  avec  $Q_0$  et  $R_0$

#### 4.4.4 Identification des entrées pertinentes

A ce jour, à notre connaissance, il n'existe pas de méthode de sélection des entrées pertinentes pour la technique du filtre de Kalman contrairement aux RNAs. En effet, ces derniers peuvent utiliser la méthode ARD [7]. Dans ce contexte, le critère de sélection appliqué pour le modèle hybride de Kalman repose sur le RMSE. En effet, le RMSE permet la comparaison de méthodes de prévision. La sélection des entrées pertinentes et leur ordre optimal ont été faits à partir de la recherche du RMSE minimum obtenu pour une prévision du GHI avec un horizon de 1h.

La liste des entrées à tester s'appuie principalement sur le modèle numérique. En effet, il produit la prévision de plusieurs variables atmosphériques. Sur la base de l'étude bibliographique des travaux de Badosa et al. [3], certaines variables atmosphériques sont retenues pour la sélection des entrées pertinentes. Il s'agit de l'altitude du géopotential 850hPa, la pression atmosphérique, l'humidité relative, la température à 2m et les moyennes spatiales du GHI. Cette dernière représente la moyenne des mesures du GHI situées sur les pixels contigus au point considéré pour la prévision. La Figure 4.9 illustre la méthode appliquée pour faire la moyenne spatiale du GHI de 9, 25 et 49 pixels contigus soit  $3 \times 3$ ,  $5 \times 5$  et  $7 \times 7$  pixels.

Par ailleurs, le cosinus de l'angle solaire zénithal, la mesure pyranométrique sur site, la prévision numérique et l'estimation du ciel clair avec le modèle Bird du GHI sont testés. La

notation symbolique utilisée pour chacune des variables testées est détaillée dans le tableau 4.1.

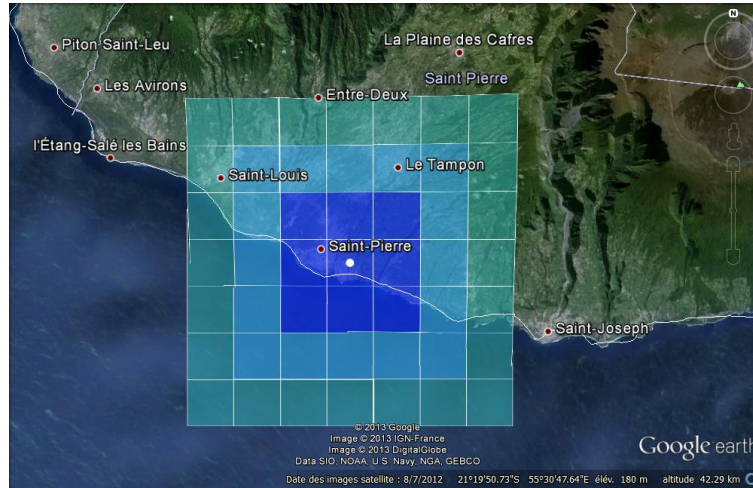


FIGURE 4.9 Moyenne spatiale du GHI des pixels contigus au site

Symbole	Signification
$GHI$	Global Horizontal irradiance ou rayonnement global horizontal
Geopotentiel	Altitude du géopotentiel 850 hPa
RH	Humidité relative
Temp 2m	Température à 2 m
$3 \times 3$	Moyenne spatiale du rayonnement sur 9 pixels contigus
$5 \times 5$	Moyenne spatiale du rayonnement sur 25 pixels contigus
$7 \times 7$	Moyenne spatiale du rayonnement sur 49 pixels contigus
$\widehat{k}_{t+h wrf}^*$	Indice de ciel déduit du modèle numérique à l'horizon $t + h$
$k_{t sol}^*$	Indice de ciel clair mesuré au sol à l'instant $t$
$\cos(\theta_{t+h})$	Cosinus de l'angle solaire zénithal pour l'instant $t + h$

TABLE 4.1 Notation des variables d'entrées testées.

La procédure de sélection des entrées se résume à appliquer d'abord les entrées utilisées par Pelland [77]. Ensuite, l'investigation se poursuit à travers le test des entrées optimales en terme d'ordre, de nombre et de nature. L'objectif de cette méthode est d'identifier la combinaison de variables d'entrée produisant la meilleure performance par rapport au RMSE. Une année de données est utilisée pour tester les méthodes de sélection des entrées.

#### 4.4.4.1 Modèle de Pelland : entrées de rayonnement à l'ordre 1

Dans un premier temps, les entrées utilisées par Pelland sont testées. Ainsi, la prévision du rayonnement global faite avec le modèle numérique pour l'horizon  $t + h$ , noté  $GHI_{t+h|wrf}$ , et la mesure pyranométrique du rayonnement global à l'instant  $t$ , noté  $GHI_{t|sol}$ , sont utilisées comme données d'entrées de l'algorithme. La sortie de l'algorithme représente la prévision du biais sur le GHI produit par le modèle numérique WRF pour l'horizon  $t + h$ .





FIGURE 4.10 Synthèse de la prévision du biais avec le modèle de Pelland.

La Figure 4.10a illustre les entrées<sup>3</sup> et la sortie de la méthode utilisée par Pelland et al [77]. La Figure 4.10b présente la précision des prévisions par rapport aux mesures pyranométriques sur site.

La performance de prévision à l'horizon de 1 heure correspond à un RMSE relatif de 25.19% et un MBE relatif de 0.36%. Cette précision du modèle obtenu à partir du GHI en entrée nous semble pouvoir être améliorée en utilisant entre autre l'indice de ciel clair en lieu et place du GHI.

3. Dans l'algorithme de Pelland, le GHI est divisé par 1000 pour normaliser. Par analogie, l'entrée utilisée est  $\frac{GHI_{t+h|wrf}}{1000}$

Dans cette optique, la recherche d'amélioration de la performance de prévision s'intéresse d'une part à l'ordre sur les entrées de l'algorithme, d'autre part, elle étudie l'impact de l'utilisation d'une entrée alternative au GHI et/ou une entrée supplémentaire dans le modèle hybride.

#### 4.4.4.2 Modulation de l'ordre des entrées en rayonnement

La recherche de l'ordre optimal des entrées revient à augmenter progressivement la valeur de l'ordre. Cette procédure est testée d'une part sur le rayonnement solaire global et de l'autre sur l'indice de ciel clair du modèle numérique.

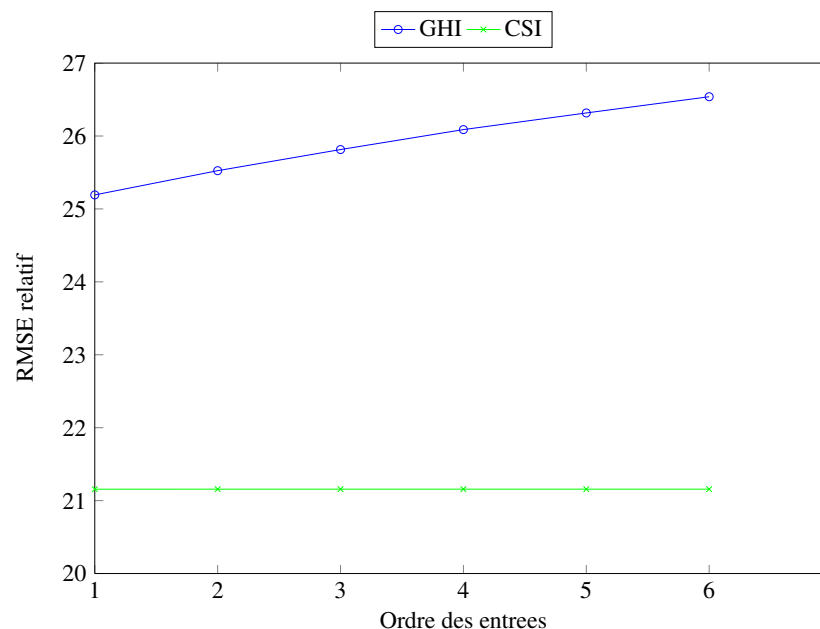


FIGURE 4.11 Variation du RMSE relatif en fonction de l'ordre des entrées.

Les résultats de ce test sur l'ordre des entrées, synthétisés dans la Figure 4.11, montrent que les meilleures performances sont obtenues avec l'ordre 1. En effet, pour les deux variables d'entrées évaluées, le plus faible RMSE est observé avec l'ordre 1. Par conséquent, ce dernier est retenu pour la suite des calculs.

#### 4.4.4.3 Entrées additionnelles : variables atmosphériques

La recherche d'entrée optimale de cette partie s'intéresse à la combinaison du GHI avec des variables supplémentaires produites par le modèle numérique de prévision. Ainsi, les variables atmosphériques et le cosinus de l'angle solaire zénithal, détaillés dans le tableau 4.1, sont testés. Dans ce contexte, ils sont utilisés respectivement comme variable d'entrée



supplémentaire de l'algorithme en plus de la prévision numérique  $\frac{GHI_{t+h|wrf}}{1000}$  et de la mesure pyranométrique<sup>4</sup>  $\frac{GHI_{t|sol}}{1000}$ . La sortie de cette nouvelle configuration est le biais sur le GHI. La Figure 4.12a illustre les entrées et la sortie de l'algorithme.

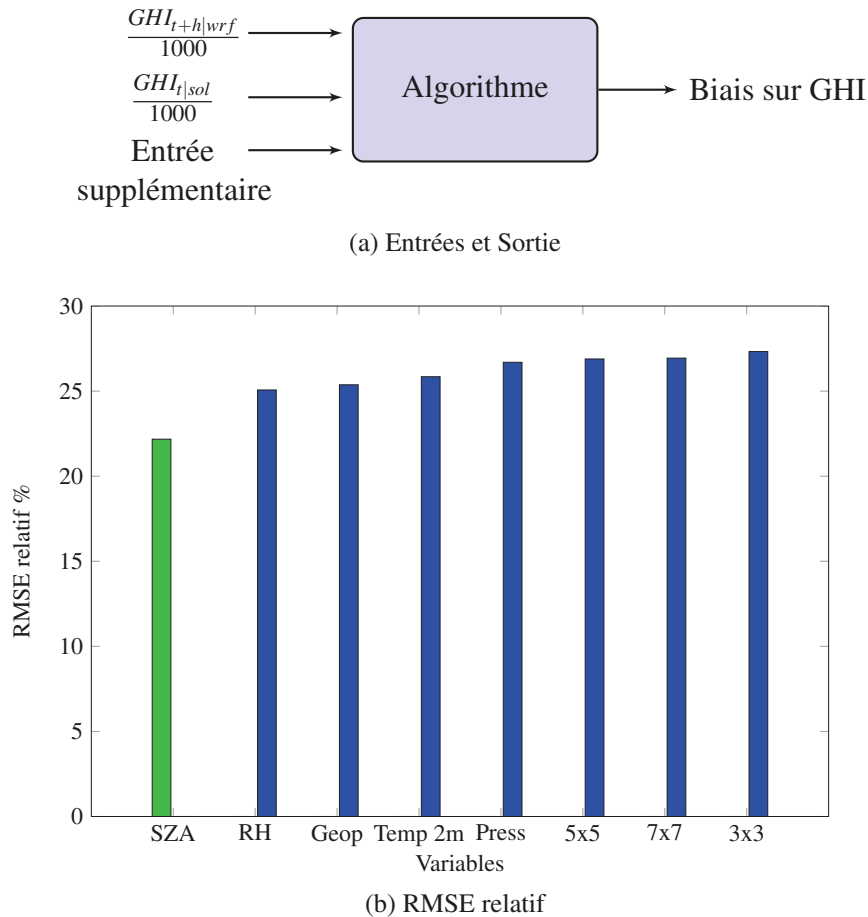


FIGURE 4.12 Variation du RMSE relatif en fonction de la variable supplémentaire.

Les résultats de cette investigation montrent que l'utilisation de la moyenne spatiale du rayonnement sur les pixels contigus, de la pression atmosphérique ou encore de la température à 2 m, occasionne un RMSE relatif supérieur à 25%. Ce résultat n'est pas performant par rapport aux entrées proposées par le modèle de Pelland.

Une amélioration de la qualité de la prévision est observée avec l'humidité relative ou encore l'altitude géopotentielle à 850hPa comme variable supplémentaire. En effet, le RMSE observé est inférieur à 25%. Cependant, le meilleur résultat de cette investigation est observé avec l'application du cosinus de l'angle solaire zénithal. En effet, le RMSE relatif obtenu est de 22.17%. La Figure 4.12b précise le résultat obtenu pour chaque variable

4.  $GHI_{t|sol}$  est divisé par 1000 pour normaliser la mesure pyranométrique du GHI.

d'entrée supplémentaire aux GHIs.

Ces résultats nous amènent à penser que l'angle solaire zénithal est une variable à prendre en compte dans la construction du modèle. Ce résultat est d'ailleurs conforté par l'analyse du biais effectuée au paragraphe 3.2.4. En effet, l'angle solaire zénithal représente une option non négligeable pour améliorer la qualité de la prévision. Cependant, la recherche d'entrées optimales se poursuit car la valeur du RMSE gagnerait à être réduite. Dans cette optique, l'indice de ciel clair est évalué pour une entrée alternative aux GHIs.

#### 4.4.4.4 Indice de ciel clair

La recherche d'entrée optimale de cette partie s'intéresse à l'utilisation d'une alternative aux GHIs à travers les indices de ciel clair. Jusqu'à présent, le GHI était divisé arbitrairement par 1000, en guise de normalisation, par analogie aux entrées de Pelland. Dans cette partie, il est question de remplacer le GHI et sa méthode de normalisation par l'indice de ciel clair. En effet, cette dernière a naturellement une valeur comprise entre 0 et 1.2. Elle est intrinsèquement liée à sa définition de rapport entre le GHI prédit ou mesuré et l'estimation par ciel clair.

Le choix de remplacer le rayonnement par l'indice de ciel clair est justifié par la large utilisation de ce dernier dans le domaine de la prévision solaire. Ainsi, les entrées alternatives utilisées sont  $\widehat{k}_{t+h|wrf}^*$  l'indice de ciel clair prédit par le modèle numérique pour l'horizon  $t + h$  et  $k_{t|sol}^*$  l'indice de ciel clair mesuré à l'instant  $t$ . Les équations (4.6) et (4.7) présentent respectivement les expressions de  $\widehat{k}_{t+h|wrf}^*$  et  $k_{t|sol}^*$ . La variable  $GHI_{t|Bird}$  représente l'estimation par ciel clair du GHI faite avec le modèle Bird [6].

$$\widehat{k}_{t+h|wrf}^* = \frac{GHI_{t+h|wrf}}{GHI_{t|Bird}} \quad (4.6)$$

$$k_{t|sol}^* = \frac{GHI_{t|sol}}{GHI_{t|Bird}} \quad (4.7)$$

La sortie de l'algorithme est la prévision du biais sur l'indice de ciel clair numérique. La Figure 4.13a présente les entrées et la sortie de cette méthode.

La prévision du GHI déduite de celle du biais sur l'indice de ciel clair numérique est comparé aux mesures pyranométriques sur site. Cette comparaison est représentée par les points rouges de la Figure 4.13b. Les points noirs sur cette figure illustre la comparaison des mesures pyranométriques aux prévisions du GHI faites à partir des entrées de Pelland. La ligne verte de la Figure 4.13b représente le résultat de la prévision idéale. Le principal





FIGURE 4.13 Prévision du biais de l'indice de ciel clair du modèle WRF à l'horizon de 1h.

résultat observé avec l'application de l'indice de ciel clair à la place du GHI est la réduction de la dispersion des points. En effet, ces derniers se rapprochent de la courbe idéale. Cette observation traduit une amélioration de la qualité de la prévision par rapport à l'application directe de la méthode de Pelland. Ce constat est confirmé par le RMSE relatif proche de 21.35%.

D'une part, l'application du cosinus de l'angle solaire zénithal comme variable d'entrée supplémentaire aux GHIs apporte une amélioration à la qualité de la prévision. De l'autre, les indices de ciel clair appliqués comme variables d'entrée alternatives aux GHIs occasionnent une grande amélioration de la performance. Par conséquent, la recherche d'entrées pertinentes se poursuit avec la combinaison des indices de ciel clair et des variables supplémentaires respectivement.

#### 4.4.4.5 Indice de ciel clair et variables atmosphériques supplémentaires

La recherche d'entrée optimale de cette section s'intéresse à l'utilisation de variables supplémentaires associées à l'indice de ciel clair. La méthode est synthétisée dans la Figure 4.14. Les entrées sont  $\hat{k}_{t+h|wrf}^*$ ,  $k_{t|sol}^*$  et la variable supplémentaire. La sortie est la prévision du biais sur l'indice de ciel clair numérique. Ils sont illustrés par la Figure 4.14a.

La qualité de la prévision obtenue pour chaque variable supplémentaire testée est quan-

tifiée avec le RMSE relatif et est représentée par la Figure 4.14b. Cette dernière montre que le meilleur résultat est observé avec le cosinus de l'angle solaire zenithal comme variable supplémentaire combiné à l'indice de ciel clair. En effet, le RMSE relatif est de 21,16%.

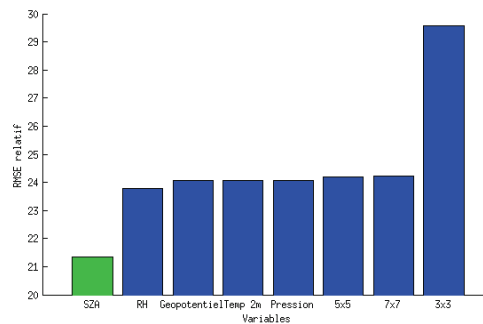



FIGURE 4.14 RMSE relatif en fonction des entrées

#### 4.4.4.6 Synthèse des résultats

L'investigation des entrées pertinentes de l'algorithme du modèle hybride a été l'occasion de tester les entrées de la méthode de Pelland, l'ordre des entrées, l'indice de ciel clair et la liste des variables présentée dans le tableau 4.1.

Le meilleur résultat obtenu pour chacune des méthodes évaluées est présenté, à travers le RMSE relatif, dans le tableau 4.2. La meilleure performance est réalisée avec les entrées composées de l'indice de ciel clair mesuré, de l'indice de ciel de clair issu de la prévision numérique et du cosinus de l'angle solaire zénithal. Par conséquent, ces derniers sont retenus comme variables d'entrée de la méthode hybride de Kalman.

Entrées	RMSE relatif	MBE relatif
$\frac{GHI_{t+h wrf}}{1000}, \frac{GHI_{t sol}}{1000}$	25.19%	0.36%
$\frac{GHI_{t+h wrf}}{1000}, \frac{GHI_{t sol}}{1000}, \cos(\theta_{t+1})$	22.17%	0.35%
$\hat{k}_{t+h wrf}^*, k_{t sol}^*$	21.33%	0.29%
$\hat{k}_{t+h wrf}^*, k_{t sol}^*, \cos(\theta_{t+1})$	21.16%	0.19%

TABLE 4.2 Performances de prévision en fonction des entrées à l'horizon de 1h.

## 4.5 Conclusion

Ce chapitre décrit le modèle hybride de Kalman développé au cours de cette thèse pour faire des prévisions à très court terme du GHI. La première version du modèle réalise la prévision du biais du pas de temps suivant tandis que la deuxième produit plusieurs horizons de prévisions du biais du modèle numérique.

L'établissement du modèle hybride est basé sur un algorithme inspiré du filtre de Kalman. Il s'ensuit une phase d'initialisation et de calibration de l'algorithme. La sélection des entrées pertinentes a été faite en partant de l'algorithme de Pelland et de ses variantes. Ce test aboutit au choix de l'angle solaire zénithal et de l'indice de ciel clair comme variables d'entrées du modèle hybride.

# Chapitre 5

## Performances des méthodes de prévision

Ce chapitre propose de comparer la performance des méthodes de prévision proposées avec celle identifiée lors de l'étude bibliographique. Pour ce faire, deux stations météorologiques de l'île de La Réunion aux caractéristiques climatiques différentes sont exploitées.

### Sommaire

---

<b>5.1</b>	<b>Introduction</b>	<b>89</b>
<b>5.2</b>	<b>Analyse des sites</b>	<b>89</b>
5.2.1	Propriétés géographiques	90
5.2.2	Matériel et mesures	91
5.2.3	Contrôle de la qualité des mesures	91
5.2.4	Classification de l'ensoleillement	92
<b>5.3</b>	<b>Performances des prévisions à court terme</b>	<b>97</b>
5.3.1	Prévisions avec le modèle de persistance	97
5.3.2	Prévisions du modèle numérique WRF	98
5.3.2.1	Indices de ciel clair et saisonnalité	99
5.3.2.2	Erreurs et saisonnalité	100
5.3.2.3	Erreurs et Angle solaire zénithal	100
5.3.3	Post-procession des prévisions WRF avec un modèle neuronal	102
5.3.3.1	Erreurs et saisonnalité	103
5.3.3.2	Erreurs et Angle solaire zénithal	104
5.3.4	Comparaison des performances de prévision	105
<b>5.4</b>	<b>Performances des prévisions à très court terme</b>	<b>107</b>
5.4.1	Prévisions énergétiques de la persistance	107
5.4.2	Prévisions énergétiques du modèle hybride de Kalman	108

5.4.3	Comparaison des performances de prévisions énergétiques . . . .	110
5.4.4	Prévisions multihorizon du modèle hybride de Kalman . . . . .	112
<b>5.5</b>	<b>Conclusion . . . . .</b>	<b>114</b>

---

## 5.1 Introduction

L'étude comparative des méthodes de prévision démarre par une analyse des sites en terme de propriétés géographiques, de matériels installés et de contrôle qualité des mesures historiques. La typologie de l'ensoleillement à travers la variabilité spatiale et temporelle est également évaluée.

Ensuite, la performance des prévisions à court terme est étudiée avec un horizon de 1 jour à l'avance. La dernière partie est consacrée à l'évaluation des prévisions à très court terme. La persistance, le modèle hybride de Kalman et le modèle hybride neuronal sont testés sur des horizons de prévision variant de cinq minutes à 3 heures.

## 5.2 Analyse des sites

Les données de rayonnement horizontal global exploitées dans cette étude ont été mesurées sur deux stations météorologiques de La Réunion qui se situent à Saint-Pierre et au Tampon. La pertinence du choix stratégique de ces sites est justifiée à travers une analyse approfondie de leurs caractéristiques.



FIGURE 5.1 Stations météorologiques.



### 5.2.1 Propriétés géographiques

Les stations météorologiques sont localisées au sud de La Réunion. Leurs positions géographiques sont illustrées par la Figure 5.1. Le choix des sites a été réalisé du fait de la qualité des bases de données minutes maintenue par le laboratoire PIMENT. La station de Saint-Pierre et celle du Tampon présentent des conditions micro-climatiques différentes malgré la faible distance qui les sépare (10 km). Elles offrent la possibilité de tester les modèles de prévision pour des conditions météorologiques différentes.

La première station est située sur le site de l'Institut Universitaire de Technologie (IUT) de Saint-Pierre, au point de coordonnées 21°20S ;55°29E. Le climat est chaud et humide. Sur la zone où se situe la station météo, l'altitude culmine à 72 m, la température maximale est de 33.65°C et la minimale est de 14°C. L'humidité relative varie entre 50 % et 80%. Par ailleurs, la disponibilité d'une importante base de données météorologiques a contribué au choix du site.

La deuxième station météorologique est située sur le campus universitaire du Tampon, au point de coordonnées 21°16 S ; 55°30E. Le climat est tempéré et humide. Sur la zone où se situe la station météo, l'altitude culmine à 550 m, la température maximale est de 33°C et la minimale est de 9°C. L'humidité relative varie entre 26 % et 98.1%. De plus, la station du Tampon dispose d'une importante base de données météorologiques. Cette complémentarité géographique des sites offre la possibilité de tester les méthodes de prévision sur plusieurs conditions climatiques. Le tableau 5.1 synthétise les propriétés géographiques des sites d'expérimentation.

Localisations	Saint-Pierre	Tampon
Pays	La Réunion	La Réunion
Positions géographiques	21°20S ;55°29E	21°16 S ; 55°30 E
Altitude	72 m	550 m
Températures	14°C - 33.65°C	9°C - 33°C
Humidité Relative	30 % et 80%	26 % et 98.1%
Climats	chaud et humide	tempéré et humide
Climats	tropical océanique	tropical d'altitude
Topographie	côtier, urbain	montagneux, urbain

TABLE 5.1 Propriétés des sites étudiés.

### 5.2.2 Matériel et mesures

Les stations météorologiques sont dotées de pyranomètres<sup>1</sup> étalons secondaires de la marque CMP11 Kipp & Zonen. Ces derniers réalisent des mesures de très haute précision avec une incertitude inférieure à 3% sur le cumul journalier du rayonnement. Les données sont enregistrées toutes les minutes et résultent de la moyenne de mesures faites toutes les 6 secondes. Le pyranomètre, illustré par la Figure 5.2, mesure le rayonnement global sur un plan horizontal.



FIGURE 5.2 CMP11 Kipp & Zonen

Les mesures ont démarré sur le site de Saint-Pierre en 2006 et sur celui du Tampon en 2010. Elles sont à l'origine d'une importante base de données historiques. De la qualité de ces mesures pyranométriques dépend la performance des méthodes de prévisions proposées. Dans ce contexte, le contrôle de leur qualité devient incontournable.

### 5.2.3 Contrôle de la qualité des mesures

L'objectif du contrôle de la qualité des données est de vérifier leurs présences et leurs cohérences physiques. Les tests s'inspirent de la méthode SERI-QC du laboratoire NREL [65]. Dans la mesure où l'étude s'intéresse à la qualité du rayonnement global mesuré, seuls les tests directement appliqués au GHI sont présentés. Les conditions de validité sont définies à partir de l'indice  $k_t$ , de l'angle solaire zénithal  $\theta_z$  et du rayonnement hors atmosphère  $I_{oh}$  avec  $I_{SC}$  la constante solaire et  $n$  le numéro du jour. Les conditions de validité et les résultats de ces tests sont présentés dans le tableau 5.2.

---

1. Un pyranomètre est un capteur de flux thermique utilisé pour la mesure de la quantité d'énergie solaire en lumière naturelle.

$$k_t = \frac{GHI}{I_{oh} \times \cos(\theta_z)}$$

$$I_{oh} = I_{SC} \left[ 1 + 0.034 \cos\left(2\pi \frac{n}{365,25}\right) \right] \quad (5.1)$$

$$I_{SC} = 1367W/m^2$$

	Saint-Pierre	Tampon
Conditions d'invalidité	Taux de mesures invalides	Taux de mesures invalides
$GHI > I_{0H}$	0.12%	0.43%

TABLE 5.2 Test qualité et taux de données rejetées.

Ces résultats montrent un taux de données incorrectes très faible et proche de 0.1%. La suppression des jours ayant des données manquantes ou bien des mesures physiquement impossibles représente un taux de 11% pour le site de Saint-Pierre et 34% pour celui du Tampon. Les Figures 5.3a et 5.3b présentent respectivement une vue d'ensemble du rayonnement global disponible sur le site de Saint-Pierre avant et après l'application de la méthode SERI-QC. La faible différence entre ces deux figures montre la grande qualité des mesures faites sur les sites d'expérimentation. Par ailleurs, elles soulignent le fort ensoleillement dont bénéficie le site de Saint-Pierre.

En plus de la vérification de la qualité des mesures, il est important d'identifier le type d'ensoleillement des sites d'expérimentation. Dans ce contexte, une procédure de classification de l'ensoleillement est mise en place pour caractériser les sites.

#### 5.2.4 Classification de l'ensoleillement

La classification de l'ensoleillement quotidien des journées repose sur deux critères à savoir le type de ciel et la variabilité. La valeur moyenne journalière  $\bar{k}_{t,jour}^*$  de l'indice de ciel clair  $k_t^*$  définit le type de ciel. Dans ce contexte, trois classes de jours ont été identifiées dans les travaux de Dambreville [20] :

- la classe A où le ciel est clair et  $\bar{k}_{t,jour}^*$  est supérieur à 0.8 ;
- la classe B où le ciel est mitigé et  $\bar{k}_{t,jour}^*$  est compris entre 0.4 et 0.8.
- la classe C où le ciel est nuageux et  $\bar{k}_{t,jour}^*$  est inférieur à 0.4 ;




FIGURE 5.3 Rayonnement Global à Saint-Pierre en 2011 et 2012 avec ou sans SERI-QC.

$$\bar{k}_{t,jour}^* = \frac{1}{N} \times \sum_{k=1}^N k_t^*(k) \quad (5.2)$$

avec  $N$  le nombre de mesures quotidiennes disponibles après le filtrage par rapport à l'angle solaire zénithal. La classification de l'ensoleillement quotidien de chaque site par rapport à la moyenne de l'indice de ciel clair est synthétisé dans le tableau 5.3 et illustré par la Figure 5.4.

	Classe A	Classe B	Classe C
Conditions	$\bar{k}_{t,jour}^* > 0.8$	$0.4 < \bar{k}_{t,jour}^* < 0.8$	$\bar{k}_{t,jour}^* < 0.4$
Saint-Pierre	55.22	42.36	2.42
Le Tampon	21.38	71.49	7.13

TABLE 5.3 Répartition en % des mesures par rapport à la qualité de l'ensoleillement.

Elle montre que le site de Saint-Pierre présente la plupart du temps un ciel clair ou mitigé alors que celui du Tampon est souvent mitigé avec quelques plus rares conditions de ciel clair.

Le deuxième critère de classification, à savoir la variabilité  $\delta \bar{k}_{t,jour}^*$ , illustrée par l'équation (5.3), est l'écart-type des changements d'indices de ciel clair selon Hoff et al. [34].

$$\delta \bar{k}_{t,jour}^* = \sqrt{\frac{1}{n_j} \times \sum_{i=1}^{n_j} (k_t^*(i+1) - k_t^*(i))^2} \quad (5.3)$$

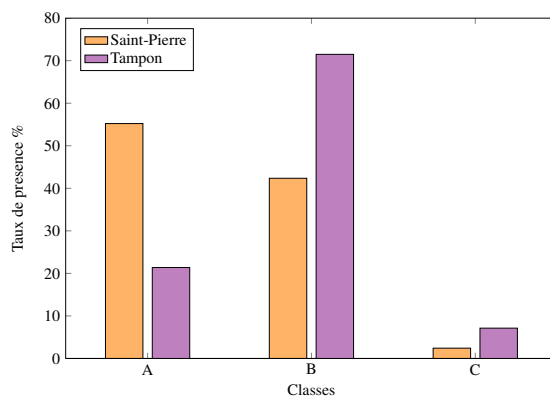


FIGURE 5.4 Distribution des mesures par rapport à la qualité de l'ensoleillement.

La variabilité  $\delta\bar{k}^*_{t,jour}$  décrit la variation intra-journalière de proche en proche de l'indice de ciel clair. Cette dernière est organisée en trois familles suivant la valeur de  $\delta\bar{k}^*_{t,jour}$  d'après les travaux de Dambreville [20] :

- la classe I où la variabilité est faible et  $\delta\bar{k}^*_{t,jour}$  est inférieur à 0.05 ;
- la classe II où l'ensoleillement est fréquemment variable et  $\delta\bar{k}^*_{t,jour}$  est compris entre 0.05 et 0.15.
- la classe III où l'ensoleillement est très variable et  $\delta\bar{k}^*_{t,jour}$  est supérieur à 0.15 ;

La classification de l'ensoleillement quotidien de chaque site par rapport à la variabilité intra-journalière de l'indice de ciel clair est synthétisée dans le tableau 5.4 et illustré par la Figure 5.5. Elle montre que les deux sites présentent un ensoleillement moyennement variant.

	Classe I	Classe II	Classe III
Conditions	$\delta\bar{k}^*_{t,jour} < 0.05$	$0.05 < \delta\bar{k}^*_{t,jour} < 0.15$	$\delta\bar{k}^*_{t,jour} > 0.15$
Saint-Pierre	23.45	74.28	2.27
Le Tampon	8.69	89.09	2.23

TABLE 5.4 Répartition en % des mesures par rapport à la variabilité.

9 classes allant de AI à CIII résultent de la combinaison des critères de qualité et de variabilité de l'ensoleillement. Un exemple d'ensoleillement quotidien de chaque classe est représenté par la Figure 5.6. La classification des journées de 2011 et 2012 par rapport à ces 9 classes est illustrée par la Figure 5.7. Le taux de répartition des mesures en fonction des classes pour chaque site est synthétisé dans les tableaux 5.5.

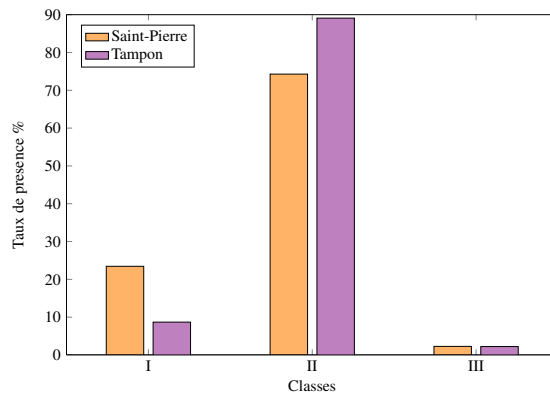


FIGURE 5.5 Classification des mesures par rapport aux classes de l'indice de ciel clair.

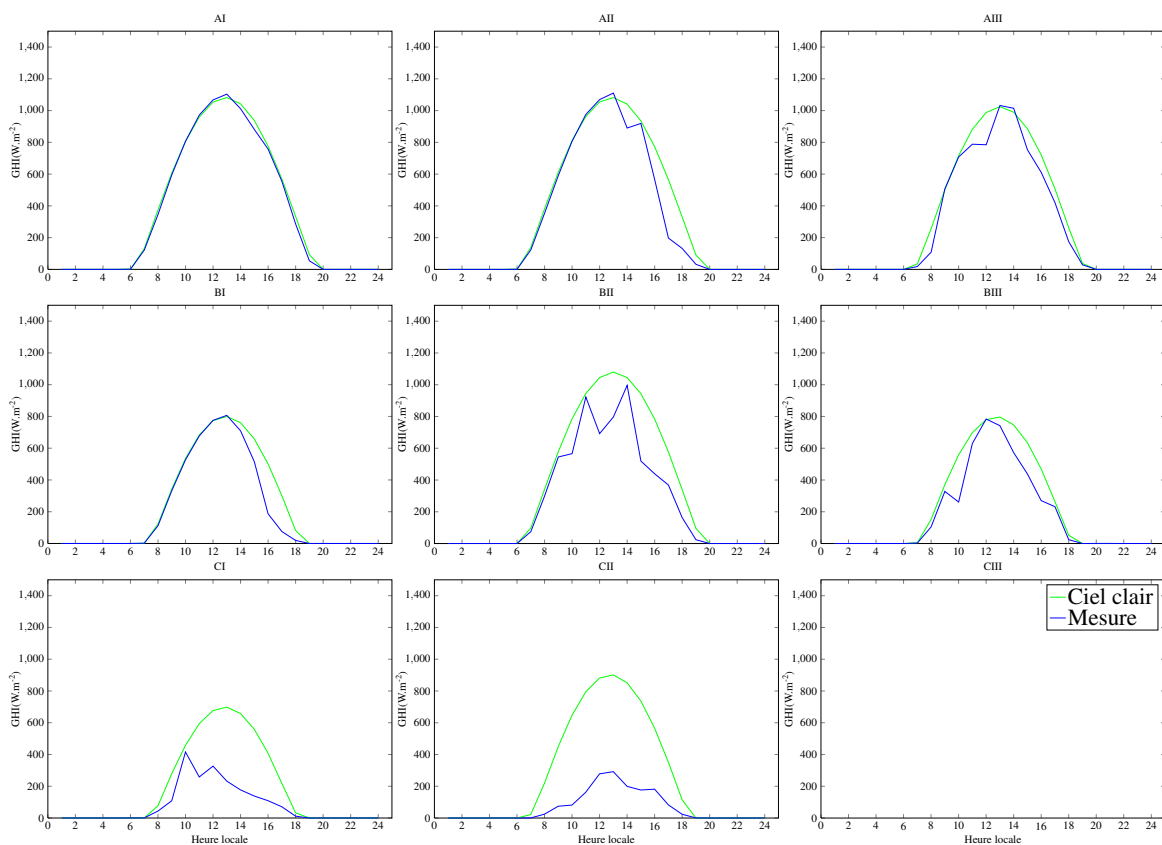


FIGURE 5.6 Exemple d'ensoleillement de chaque classe

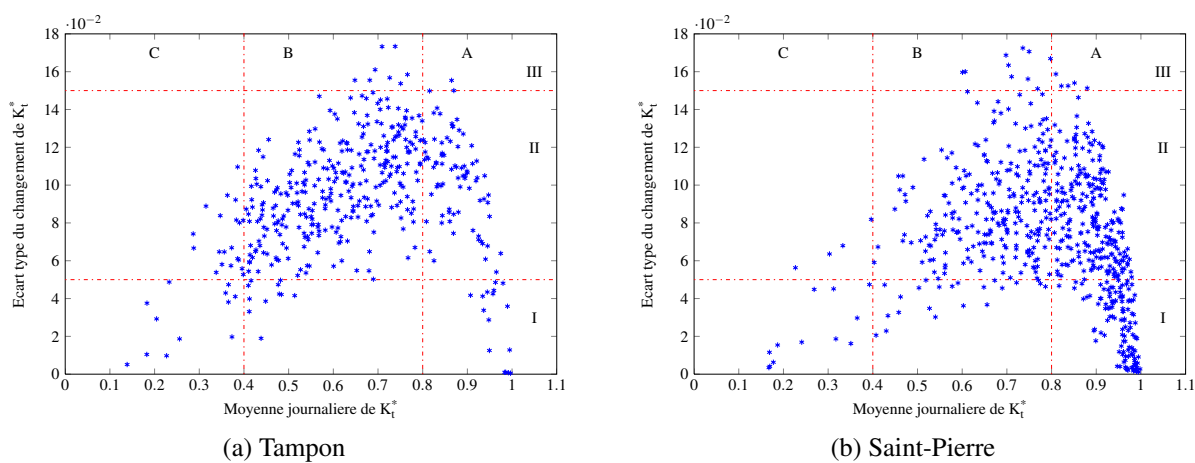


FIGURE 5.7 Classification de l'insolation.

(a) Tampon				(b) Saint-Pierre			
	Classe I	Classe II	Classe III		Classe I	Classe II	Classe III
Classe A	3.57%	17.37 %	0.46 %	Classe A	18.31%	36.16 %	0.76 %
Classe B	2.45 %	67.26 %	1.78 %	Classe B	3.33 %	37.52 %	1.51 %
Classe C	2.67 %	4.45 %	0 %	Classe C	1.82 %	0.61 %	0 %

TABLE 5.5 Classification des mesures de Saint-Pierre et du Tampon.

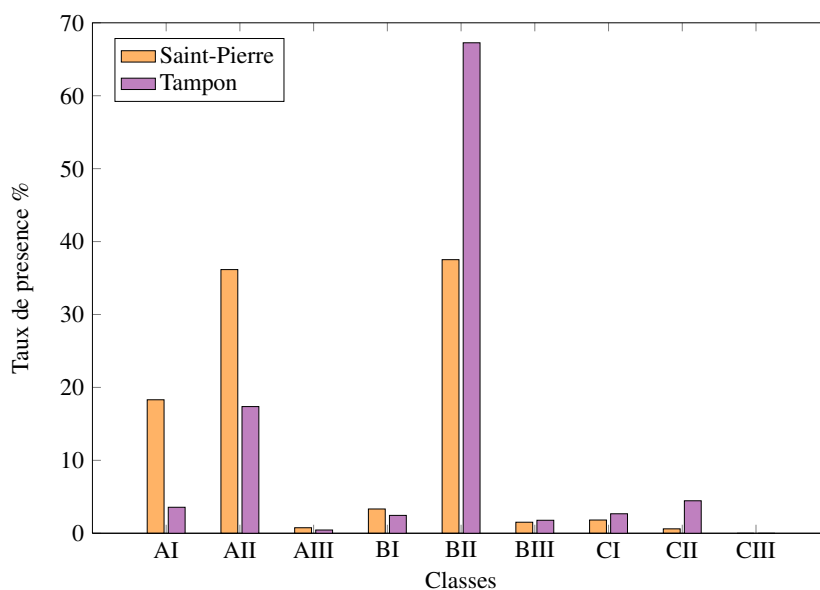


FIGURE 5.8 Classification des mesures par rapport aux critères.

La classification de l'ensoleillement à travers la qualité et la variabilité intra-journalière a permis de retenir deux résultats. Le site de Saint-Pierre présente un taux élevé de ciel clair avec une variabilité moyenne. De l'autre, le site du Tampon présente un taux élevé de ciel mitigé avec une variabilité moyenne. Par conséquent, ces deux sites offrent aux méthodes de prévision une possibilité de se confronter à plusieurs situations météorologiques.

### 5.3 Performances des prévisions à court terme

Les méthodes de prévision de cette partie regroupent la persistance, le modèle numérique WRF et le modèle neuronal. Elles s'intéressent aux prévisions réalisées la veille pour le lendemain. Leurs performances sont évaluées sur les données de l'année 2012 dans la mesure où celles de 2011 ont servi à la calibration des méthodes de prévision. Toutes les méthodes sont comparées à la technique de référence à savoir le modèle de persistance.

#### 5.3.1 Prévisions avec le modèle de persistance

La prévision du GHI de l'horizon J+1 au pas de temps horaire est faite avec la persistance de l'indice de ciel clair  $k_t^*$  de la veille pour le lendemain. Cette dernière est décrite par l'équation (5.4).

$$\widehat{GHI}_{t+h} = k_t^* \times GHI_{t+h,clear} \quad (5.4)$$

avec  $GHI_{t+h,clear}$  qui représente le rayonnement global estimé avec le modèle de ciel clair pour l'horizon  $t+h$  et  $k_t^*$  l'indice de ciel clair de l'instant  $t$ .

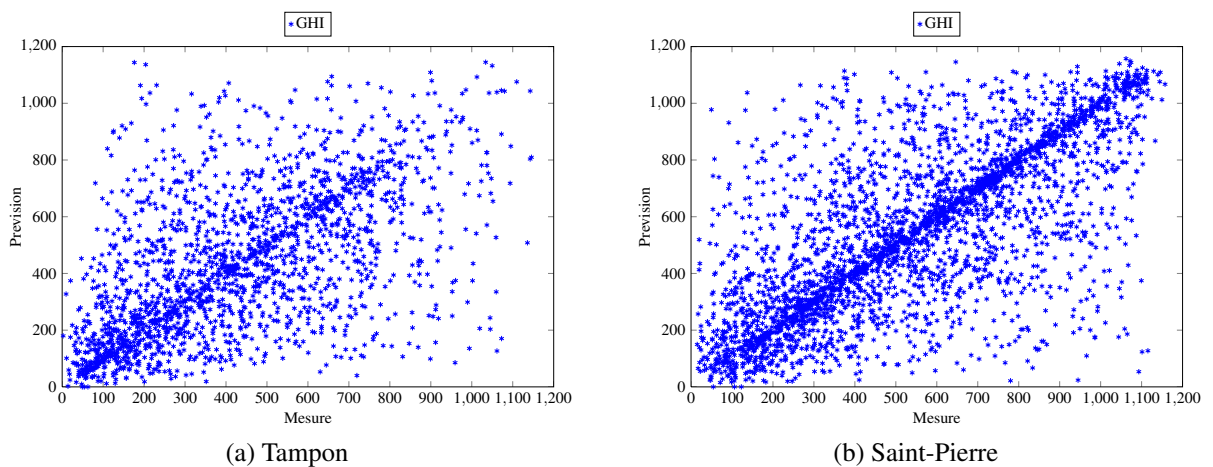


FIGURE 5.9 Prévisions du modèle persistance à t+24h



Les résultats de la persistance journalière sont comparés aux mesures pyranométriques à travers la Figure 5.9. Cette dernière montre que les prévisions sont très peu biaisées mais présentent une forte erreur quadratique moyenne. Ce constat est confirmé par les métriques d'évaluation de la qualité de la prévision avec un RMSE de 40 % et un MBE de 0,01 % pour Saint-Pierre et un RMSE de 54,6 % et un MBE de 0,56 % pour Le Tampon. Dans le but d'obtenir de meilleurs résultats de prévision, le modèle numérique WRF est testé.

### 5.3.2 Prévisions du modèle numérique WRF

Les prévisions du GHI à l'horizon J+1 faite avec le modèle numérique WRF sont comparées aux mesures pyranométriques. La Figure 5.10 présente le scatterplot de la prévision numérique de chaque site d'expérimentation.




FIGURE 5.10 Prévisions du modèle WRF à t+24h.

Cette première comparaison montre que les prévisions du modèle numérique WRF présentent une erreur quadratique moyenne plus faible que le modèle de persistance mais elles souffrent d'un biais relativement élevé. Ce constat est confirmé par les métriques d'évaluation de la qualité de la prévision avec un RMSE de 35.45% et un MBE de 7.16% pour le site de Saint-Pierre et un RMSE de 56.82% et un MBE de 16.9% pour celui du Tampon. Afin de s'assurer de la cohérence des prévisions du modèle numérique par rapport aux spécificités des stations d'expérimentation, un contrôle sur la saisonnalité par rapport à l'indice de ciel clair est réalisé.

### 5.3.2.1 Indices de ciel clair et saisonnalité

L'objectif est d'étudier la relation entre l'indice de ciel clair moyen mensuel et la saisonnalité. Dans cette optique, la vérification de l'hypothèse selon laquelle, les jours de ciel clair sont plus observés en saison sèche (d'avril à novembre) qu'en saison humide (de décembre à mars) est faite sur les mesures pyranométriques et les prévisions numériques. L'équation (5.5) présente la méthode de calcul de la moyenne de l'indice de ciel clair mensuel  $k_{t,mois}^*$  utilisé pour déterminer l'évolution mensuelle du RMSE relatif et du MBE relatif.

$$k_{t,mois}^* = \frac{\sum(GHI_{pyrano,mois})}{\sum(GHI_{Bird,mois})} \quad (5.5)$$




FIGURE 5.11 Variation mensuelle des indices de ciel clair.

La Figure 5.11 présente la variation mensuelle de l'indice de ciel clair mesuré et de l'indice de ciel clair prévu avec le modèle WRF. Elle montre une grande occurrence de ciel clair sur la période de Mai à Janvier à Saint-Pierre. La présence de ciels nuageux est dominante de Février à Avril et représente 60% de la saison humide. Par conséquent, les mesures faites sur les sites de Saint-Pierre et du Tampon permettent de confirmer cette affirmation même si pour la saison humide, elle ne se produit que 60% du temps. Cette tendance est également observée avec les prévisions numériques.

L'étape suivante consiste à étudier les fluctuations de l'erreur de prévision en fonction de la saison

### 5.3.2.2 Erreurs et saisonnalité

En vue de caractériser la précision des prévisions du modèle WRF par rapport à la saison, l'évolution mensuelle du MBE relatif et du RMSE relatif est étudiée pour chaque site. Elle est représentée respectivement par la Figure 5.12a et la Figure 5.12b.

Ainsi, sur le site de Saint-Pierre, durant la saison sèche, le MBE relatif est proche de 10% et le RMSE relatif de 32%. Durant la saison humide, le MBE relatif est proche de 18% et le RMSE de 48%. Concernant le site du Tampon, une grande occurrence de ciel couvert est observée comme l'illustre la Figure 5.11. Le MBE relatif du modèle WRF est proche de 20% et le RMSE de 45%.

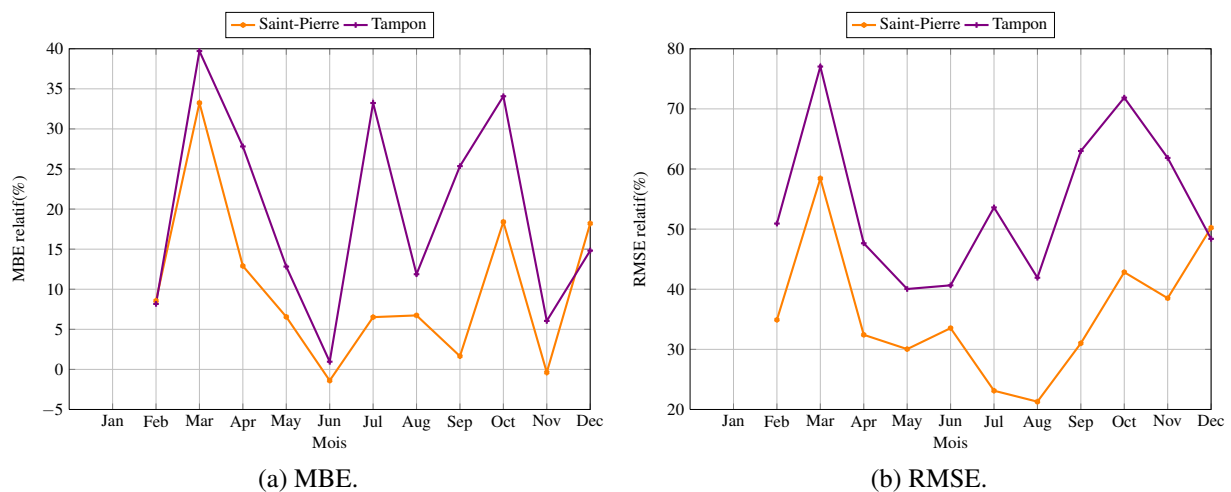


FIGURE 5.12 Variation mensuelle du MBE et du RMSE relatif avec le modèle WRF.

Ces résultats indiquent que le modèle numérique WRF fournit une meilleure performance de prévision par ciel clair. Le modèle WRF affiche cependant un biais relativement important. Les performances du modèle WRF peuvent être donc améliorées par une correction appropriée du biais.

### 5.3.2.3 Erreurs et Angle solaire zénithal

L'objectif de cette étape est d'étudier l'erreur de prévision du modèle WRF en fonction de la position du soleil et de l'indice de ciel clair. Dans ce contexte, la Figure 5.13 représente la variation de l'erreur de prévision en fonction de l'angle solaire zénithal et l'indice de ciel clair prévu par le modèle WRF. Elle montre que le modèle WRF sur-estime le GHI par ciel clair. En outre, elle sous-estime la prévision du GHI lorsque l'angle solaire zénithal est grand et l'indice de ciel clair prévu petit.

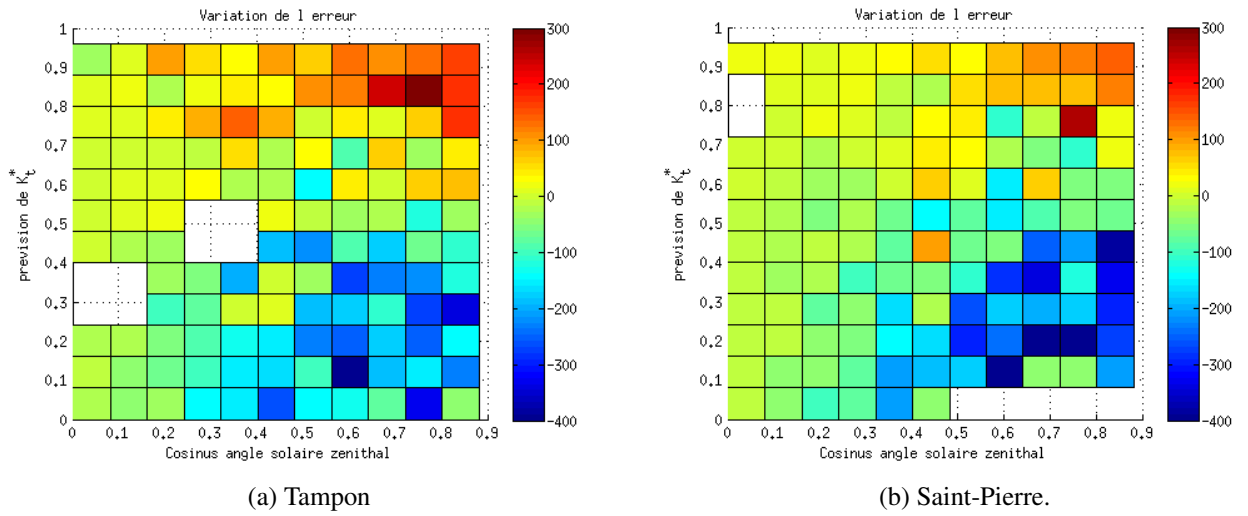


FIGURE 5.13 Variation du biais prévisionnel  $k_t^*$  en fonction de  $\cos(\text{SZA})$ .

La Figure 5.14 illustre la prévision du GHI pour chaque type de jour et chaque méthode de prévision ainsi que la mesure réelle correspondante et l'estimation par ciel clair avec le modèle Bird.

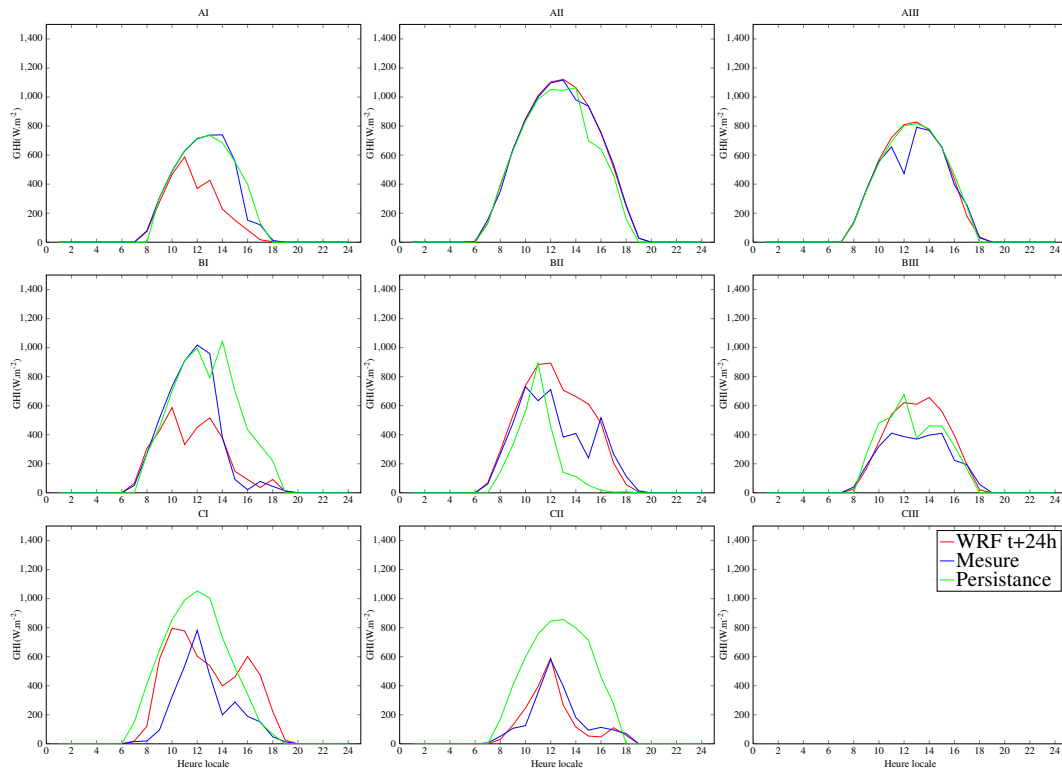


FIGURE 5.14 Exemple de prévisions de chaque type de jour à l'horizon t+24h.

### 5.3.3 Post-procession des prévisions WRF avec un modèle neuronal

Le modèle neuronal bayésien produit la prévision du biais de l'indice de ciel clair du modèle numérique WRF pour le lendemain (J+1). L'indice de ciel clair  $k_t^*$  et le cosinus de l'angle solaire zénithal sont utilisés comme données d'entrée.

De cette prévision du biais numérique est déduite le GHI prévisionnel. La Figure 5.15 présente pour chaque site d'expérimentation la comparaison des prévisions neuronales de GHI aux mesures pyranométriques.

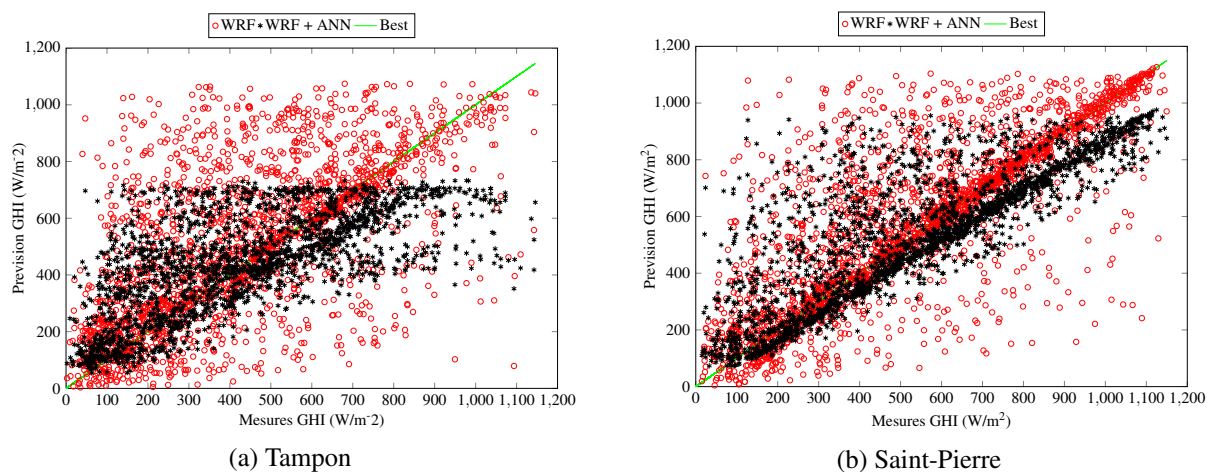


FIGURE 5.15 Prévisions du modèle WRF à t+24h.

La Figure 5.15 montre que le modèle neuronal bayésien permet de corriger efficacement le biais de la prévision obtenue avec le modèle WRF. Le RMSE est lui aussi amélioré, notamment pour le site de Saint-Pierre. Cependant, ce résultat n'est pas totalement confirmé sur le site du Tampon avec une borne haute de la prévision aux alentours de  $700\text{W}/\text{m}^2$ . En effet, une réduction de la dispersion des points est notée mais elle s'accompagne d'une diminution systématique de la valeur du GHI. Cette amélioration de la prévision du lendemain est confirmée par les métriques d'évaluation de la qualité de la prévision avec un RMSE de 30.26% et un MBE de 0.29% pour le site de Saint-Pierre et un RMSE de 43.75% et un MBE de 1.66% pour le site du Tampon.

Afin de s'assurer de la cohérence des prévisions du modèle numérique par rapport aux spécificités des stations d'expérimentation, une comparaison par rapport à l'indice de ciel clair mensuel est réalisée. La Figure 5.16 présente cette comparaison.

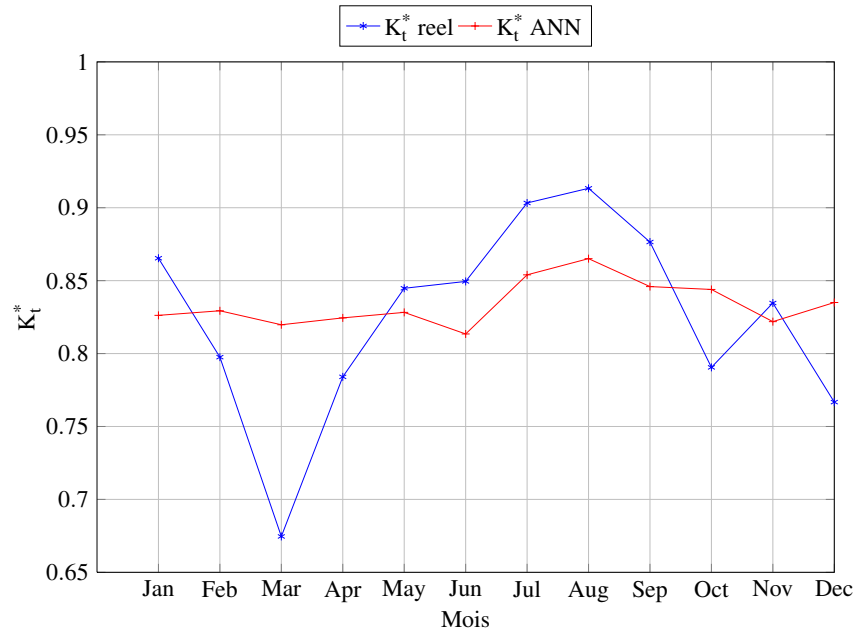


FIGURE 5.16 Comparaison des Indices de ciel clair mensuels prévus et réels.

### 5.3.3.1 Erreurs et saisonnalité

Dans l'objectif de définir la précision saisonnière des prévisions du post-processing de WRF avec le modèle neuronal, les évolutions mensuelles du MBE relatif et du RMSE relatif sont respectivement étudiées pour chaque site d'expérimentation.

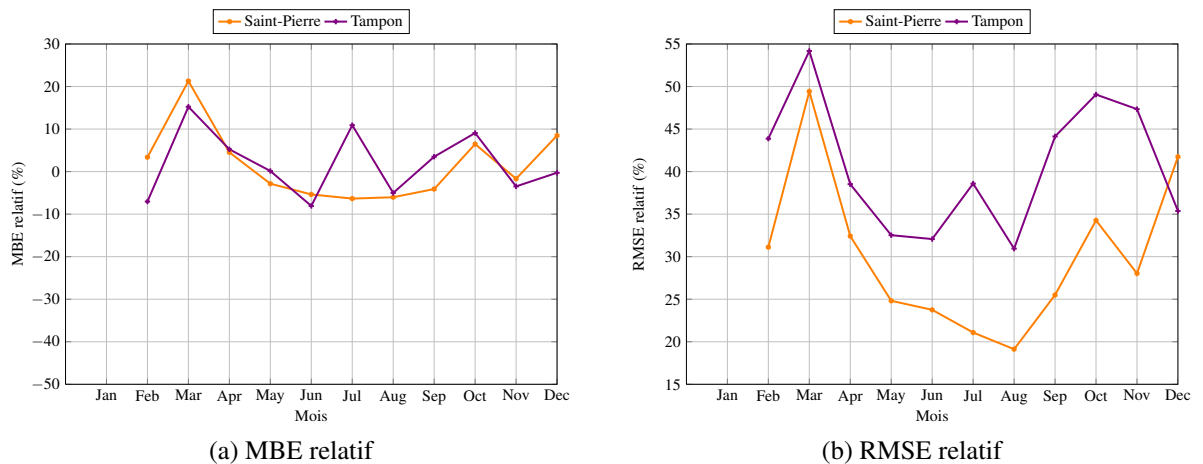


FIGURE 5.17 Variation mensuelle du MBE et du RMSE avec le modèle neuronal.

La Figure 5.17 présente les résultats. Elle montre que les prévisions sont meilleures sur le site de Saint-Pierre que celui du Tampon. Par ailleurs, sur la période de Avril à Octobre

qui correspond à l'hiver austral, le taux d'erreurs est faible avec un MBE relatif moyen de  $\pm 2\%$  et un RMSE relatif moyen de 25% pour le site de Saint-Pierre. Durant la saison humide, le MBE relatif est proche de  $\pm 10\%$  et le RMSE relatif de 48%. Le site du Tampon, présente la même tendance d'évolution de MBE et de RMSE que celui de Saint-Pierre mais la qualité de la prévision est moins bonne.

Ces résultats montrent que le post-processing de WRF avec un modèle neuronal bayésien présente une performance de prévision acceptable par ciel clair. La grande occurrence de ciel clair à Saint-Pierre amène à conclure qu'il est adéquat pour la prévision du GHI sur ce type de site.

### 5.3.3.2 Erreurs et Angle solaire zénithal

L'objectif de cette étape est d'étudier l'erreur de prévision du modèle neuronal en fonction de la position du soleil. Dans ce contexte, la Figure 5.18 représente la variation de l'erreur de prévision en fonction de l'angle solaire zénithal et l'indice de ciel clair prévu avec le modèle neuronal.

Elle montre une légère réduction de la surestimation des prévisions du GHI par ciel clair. En outre, une baisse de la sous-estimation de la prévision du GHI lorsque l'angle solaire zénithal est grand et l'indice de ciel clair prévu petit est également observé. Globalement, on observe une légère amélioration du biais après la post-procession avec le modèle neuronal.

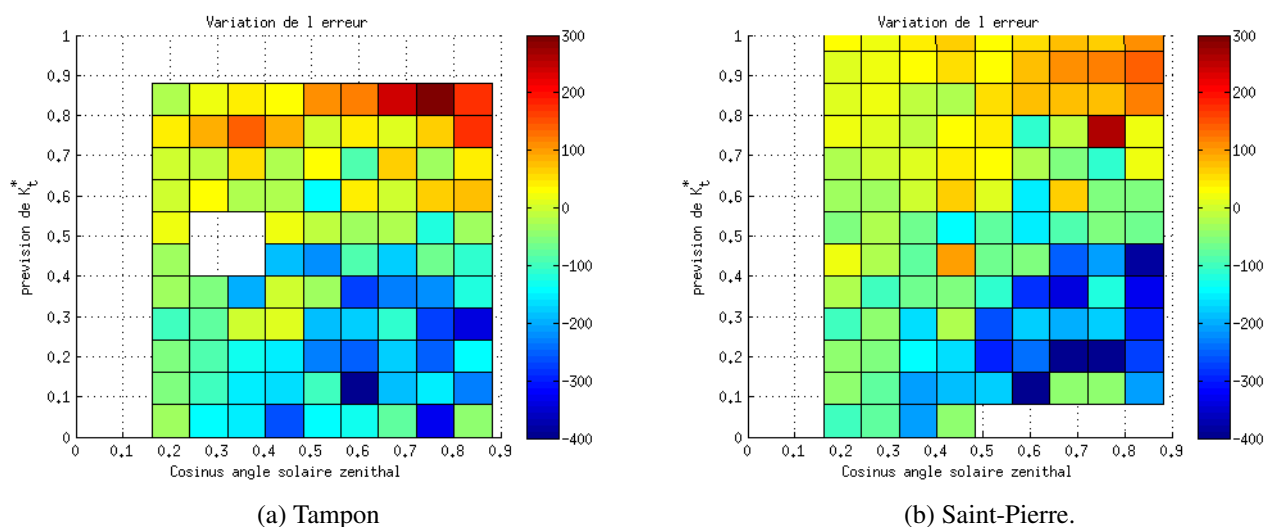


FIGURE 5.18 Variation du biais de WRF en fonction de  $\cos(\text{SZA})$  et  $k_t^*$ .

### 5.3.4 Comparaison des performances de prévision

La Figure 5.19 illustre une prévision du GHI pour chaque type de jour et chaque méthode de prévision du lendemain ainsi que la mesure réelle correspondante. La tendance générale est une amélioration de la prévision du lendemain après le post-traitement du biais avec le modèle neuronal bayésien. Cependant, cette méthode corrige les prévisions WRF initialement bonne comme le montre la classe CII de la Figure 5.19.

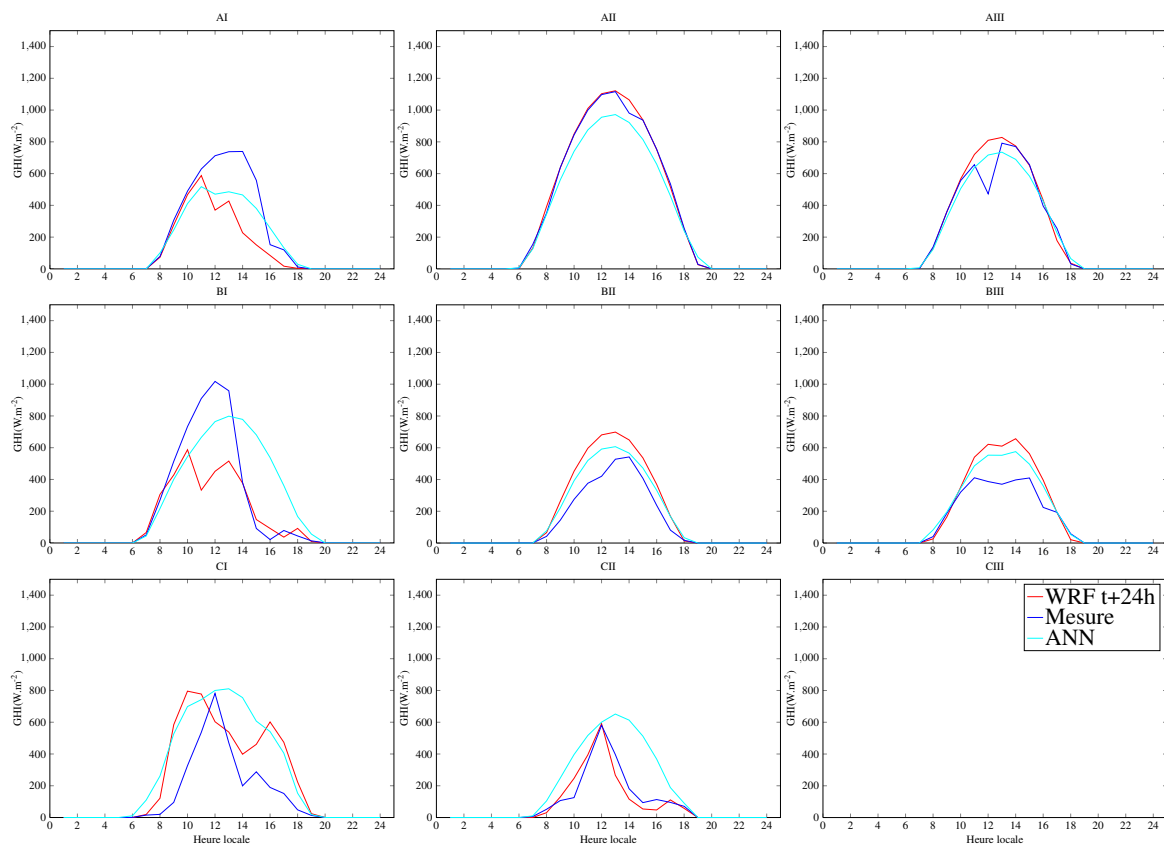


FIGURE 5.19 Exemple de prévisions du lendemain de chaque type de jour.

La qualité de la prévision de chaque type de jour en terme de RMSE relatif et de MBE relatif est illustrée par la Figure 5.20 et la Figure 5.21. Ces représentations graphiques montrent que les meilleurs résultats sont obtenus avec les jours de ciel clair (classe A) aussi bien pour le site de Saint-Pierre que celui du Tampon. De plus, les jours de ciel clair avec une faible variabilité de l'ensoleillement (classe AI) présente une tendance à une faible sous estimation par rapport aux autres type de jours sur les deux sites d'expérimentation. Le nombre de jours où le ciel est nuageux (classe C) est trop faible pour calculer de manière pertinente le RMSE et le MBE sur ce type d'ensoleillement.



De l'analyse de la qualité de la prévision en terme de RMSE relatif par type de jours résulte les conclusions suivantes :

- Les meilleures prévisions de jours de ciel clair avec une variabilité faible ou moyenne de l'ensoleillement (classes AI, AII) et les jours de ciel mitigé et moyennement variable (classe BI) sont produites avec le post-traitement du biais par le réseau de neurones ;
- Les jours de ciel clair et très variable (classe AIII) et les jours de ciel mitigé avec une variabilité moyenne ou forte (classes BII et BIII) sont mieux prévus avec modèle WRF.

Concernant le MBE relatif, le modèle numérique WRF produit la meilleure performance sur toutes les classes à l'exception des jours de ciel clair avec une faible variabilité de l'ensoleillement (classe AI) où la persistance est plus performante. Ces conclusions sont valables sur les deux sites d'expérimentation.

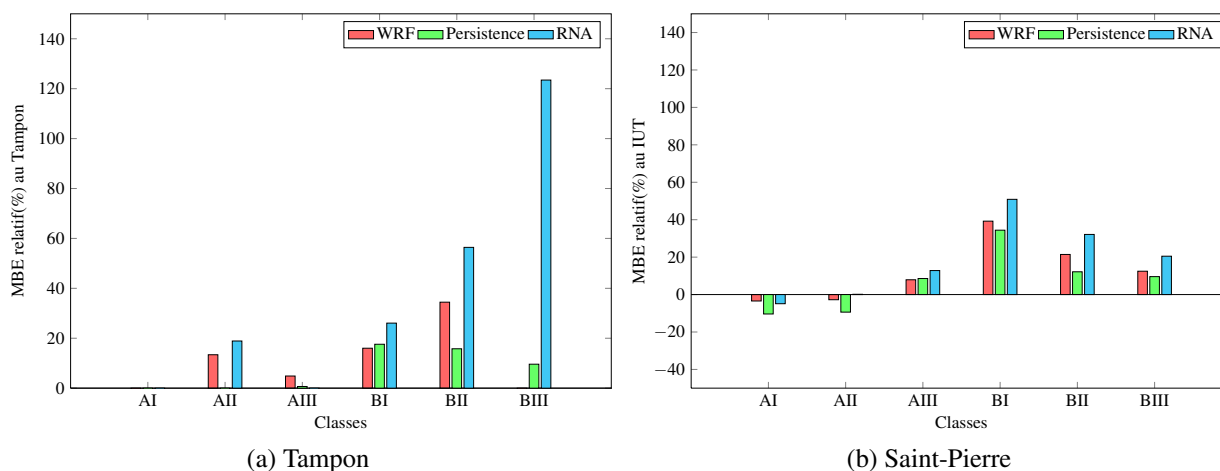


FIGURE 5.20 Variation du MBE relatif pour chaque classe d'ensoleillement.

Le tableau 5.6 synthétise les valeurs relatives du MBE et du RMSE de chaque modèle de prévision de la veille pour le lendemain et pour chaque site.

Bien que dans certains cas la méthode de correction du biais corrige dans le mauvais sens des prévisions WRF initialement correctes, le tableau 5.6 montre clairement l'intérêt du post-traitement du modèle WRF. En effet, outre l'amélioration attendue du biais, la méthode de correction permet également d'améliorer de manière importante le RMSE.




FIGURE 5.21 Variation du RMSE relatif pour chaque classe d'ensoleillement.

		Saint-Pierre	Tampon
RMSE	Persistence	40.05%	54.59%
	Modèle WRF	35.45%	56.82%
	Modèle neuronal	30.26%	43.75%
MBE	Persistence	0.01%	0.56%
	Modèle WRF	7.16%	16.9%
	Modèle neuronal	0.29%	1.66%

TABLE 5.6 Synthèse des RMSE et MBE de chaque site pour l'horizon t+24h.

## 5.4 Performances des prévisions à très court terme

Les prévisions à très court terme du GHI sont faites d'une part avec la technique de la persistance et d'autre part avec le modèle hybride de Kalman. Elles sont produites à des horizons allant de 5 minutes à 3 heures. La dernière partie de cette section est consacrée à la comparaison de leurs performances de prévision.

### 5.4.1 Prévisions énergétiques de la persistance

Les résultats de l'application de la technique de persistance sur les deux sites d'expérimentation sont illustrés par les points noirs de la Figure 5.22. Ils représentent la prévision du rayonnement global à l'horizon de 1 heure. Ces prévisions ont un RMSE relatif de 22% et un MBE relatif de 0.9% pour le site de Saint-Pierre et un RMSE relatif de 34.6% et un MBE relatif de 1.67% pour le site du Tampon. Cette étude de performance montre que la

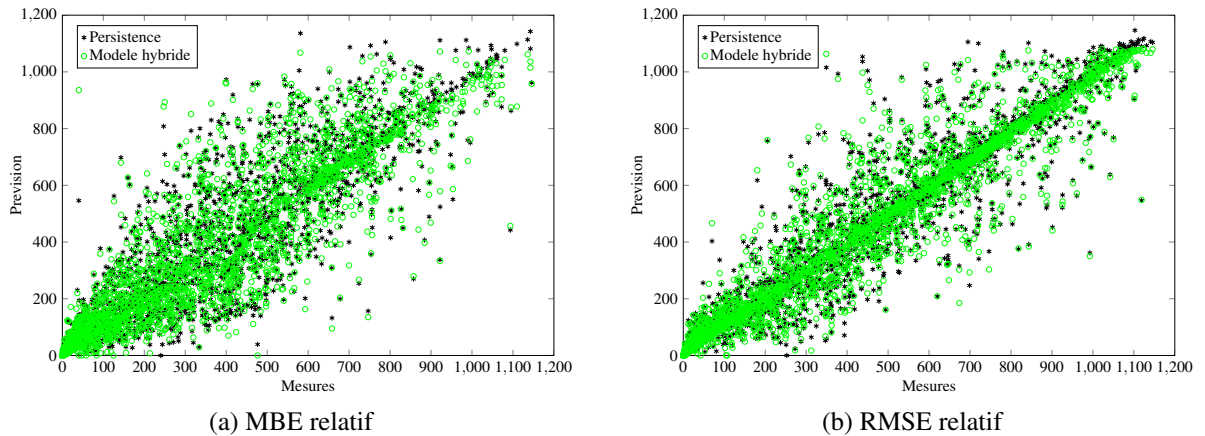


FIGURE 5.22 Comparaison des prévisions h+1 (1 heure en avance) de la persistance et du modèle hybride de Kalman avec les mesures au sol.

technique de persistance offre une qualité de précision qui gagnerait à être améliorée.

### 5.4.2 Prévisions énergétiques du modèle hybride de Kalman

Le modèle hybride de Kalman utilise l'indice de ciel clair fournit par le modèle numérique WRF et le cosinus de l'angle solaire zénithal pour produire le biais de prévision du modèle WRF. La Figure 5.23 rappelle les entrées et sorties utilisées dans cette méthode de prévision. Les résultats de l'application de la technique de persistance sur les deux sites d'expérimentation sont illustrés par les points verts de la Figure 5.22.

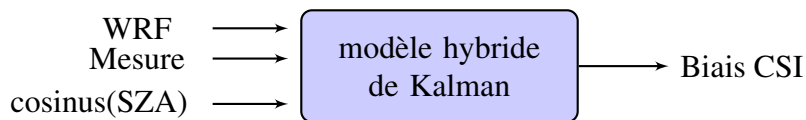


FIGURE 5.23 Entrées et Sortie du modèle hybride de Kalman.

Une étude de la variation mensuelle du MBE relatif et du RMSE relatif de chaque site d'expérimentation est présentée dans la Figure 5.24. Elle montre que les meilleurs résultats sont obtenus sur le site de Saint-Pierre.

Une étude de la variation de l'erreur de prévision en fonction de la position du soleil et de l'indice de clair est présentée dans la Figure 5.25 pour chaque site d'expérimentation. Elle montre que l'application de la méthode hybride de Kalman offre une bonne performance pour la prévision de ciels nuageux lorsque l'angle solaire est élevé.




FIGURE 5.24 Variation mensuelle du MBE et du RMSE du modèle hybride énergétique.

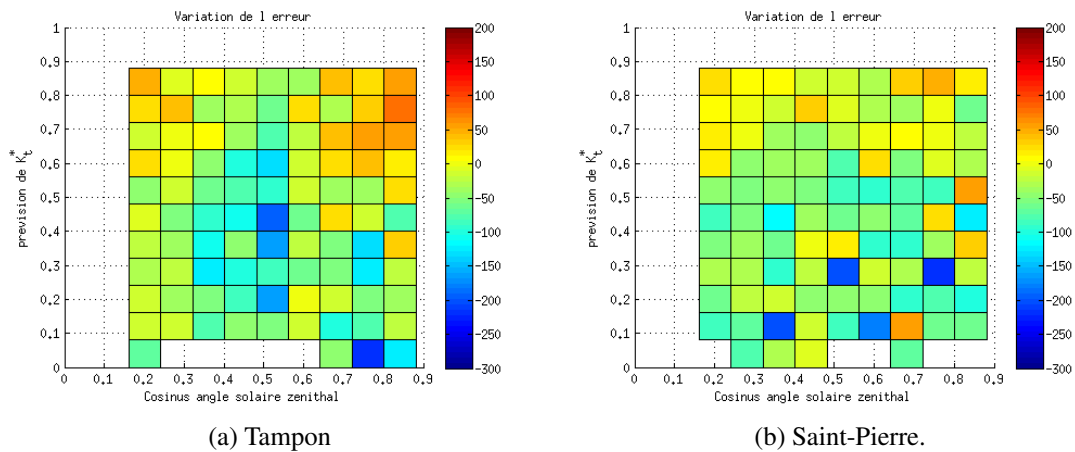


FIGURE 5.25 Erreurs de prévision en fonction de la position du soleil.

### 5.4.3 Comparaison des performances de prévisions énergétiques

La variation du MBE relatif et du RMSE relatif de chaque méthode de prévision est présentée respectivement par la Figure 5.26 et la Figure 5.27. Les horizons de prévision varient de 5 minutes à 3 heures. Ces figures montrent que la qualité de la prévision est inversement proportionnelle à l'horizon de prévision.

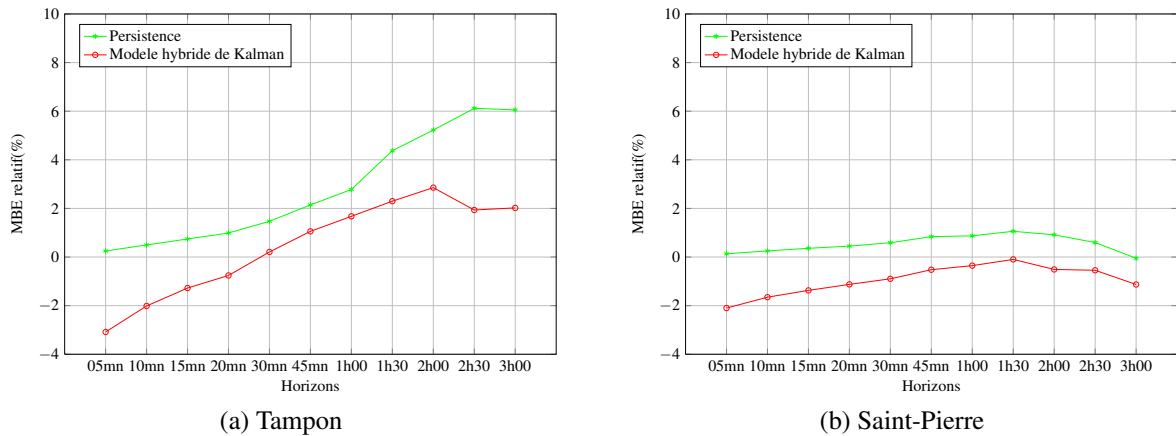


FIGURE 5.26 Variation du MBE en fonction de l'horizon de prévision énergétique.




FIGURE 5.27 Variation du RMSE en fonction de l'horizon de prévision énergétique.

La Figure 5.28 illustre la qualité de la prévision énergétique avec le modèle hybride de Kalman et la technique de persistance pour chaque type de jour avec un horizon de prévision de 1 heure.

Le tableau 5.7 synthétise la qualité de prévision énergétique obtenue pour chaque méthode pour l'horizon de prévision de 1 heure. D'après la Figure 5.28 et le tableau 5.7, il

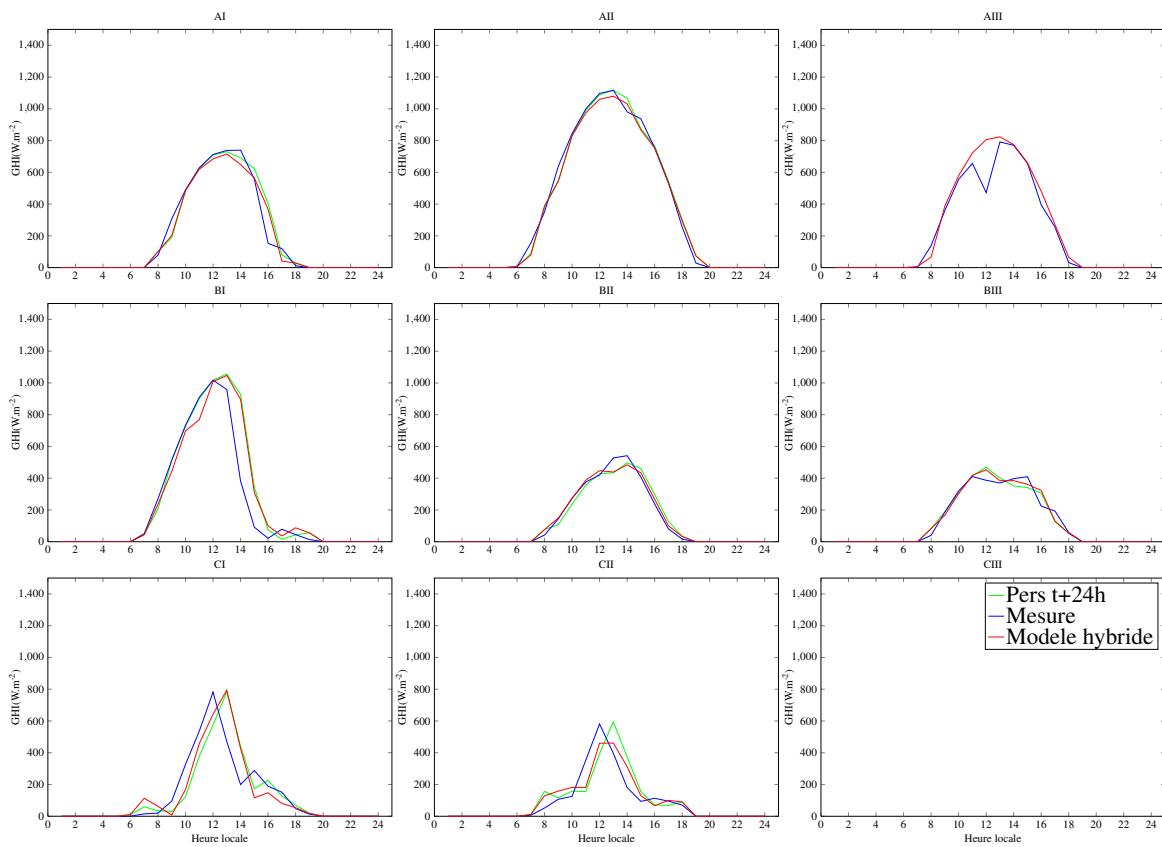


FIGURE 5.28 Exemple de prévisions énergétiques de chaque type de jour à l'horizon t+1h.

semblerait que l'apport de la méthode énergétique à  $t + 1h$  est relativement faible par rapport à la persistance. D'après la Figure 5.28, une légère amélioration est observée à partir de  $t + 1h30$

		Saint-Pierre	Tampon
RMSE	Persistance	22%	34.6%
	Kalman	21.76%	34.32%
MBE	Persistance	0.9%	1.67%
	Kalman	-0.41%	2.3%

TABLE 5.7 Synthèse des RMSE et MBE de chaque site pour l'horizon  $t+1h$ .

#### 5.4.4 Prévisions multihorizon du modèle hybride de Kalman

La variation du RMSE relatif et du MBE relatif de chaque méthode de prévision est présentée respectivement avec la Figure 5.29 et la Figure 5.30. Les horizons de prévision varient de 5 minutes à 3 heures. Ces figures montrent que la qualité de la prévision est inversement proportionnelle à l'horizon de prévision.

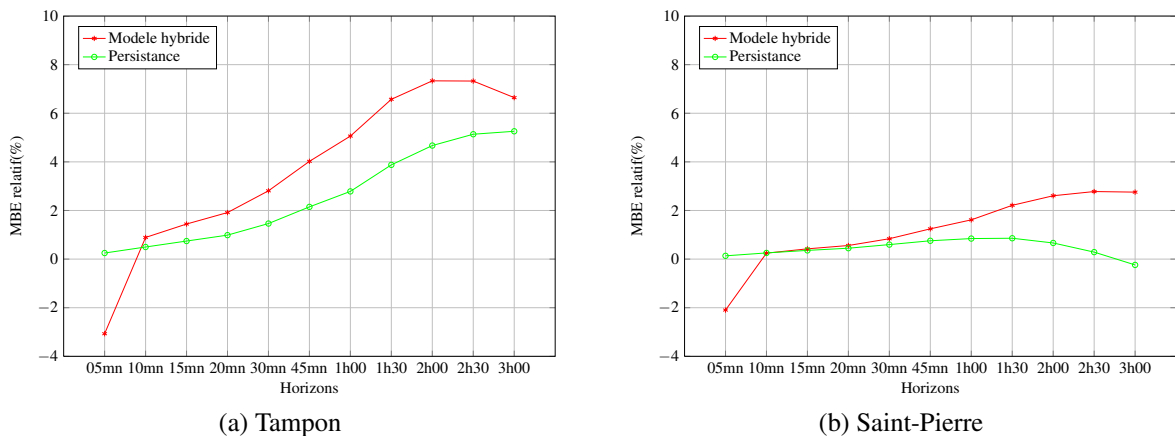


FIGURE 5.29 Variation du MBE en fonction de l'horizon de prévision du modèle hybride multihorizon.

La Figure 5.31 illustre la qualité de la prévision avec le modèle hybride de Kalman et la technique de persistance pour chaque type de jour avec un horizon de prévision de 1 heure.

Le tableau 5.8 synthétise la qualité de prévision obtenue pour chaque méthode pour l'horizon de prévision de 1 heure.

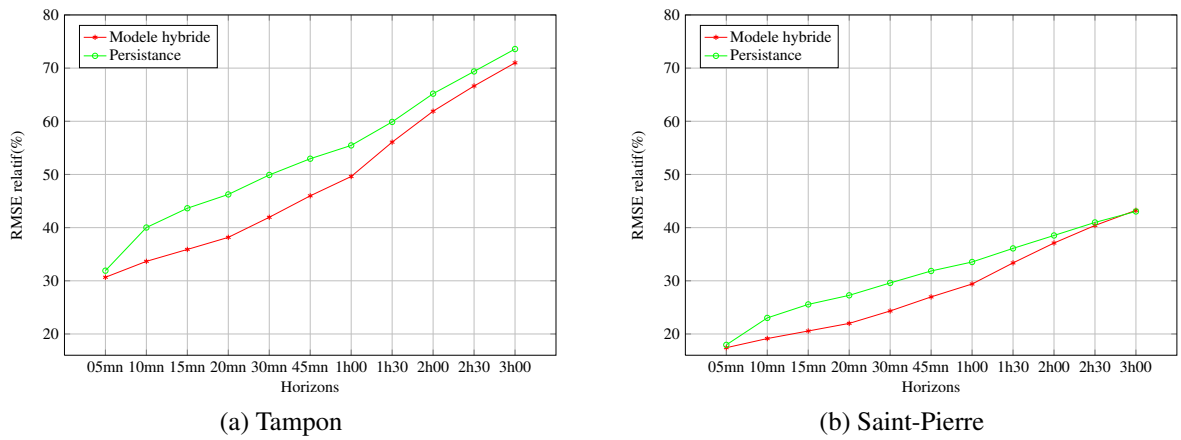


FIGURE 5.30 Variation du RMSE en fonction de l'horizon de prévision.

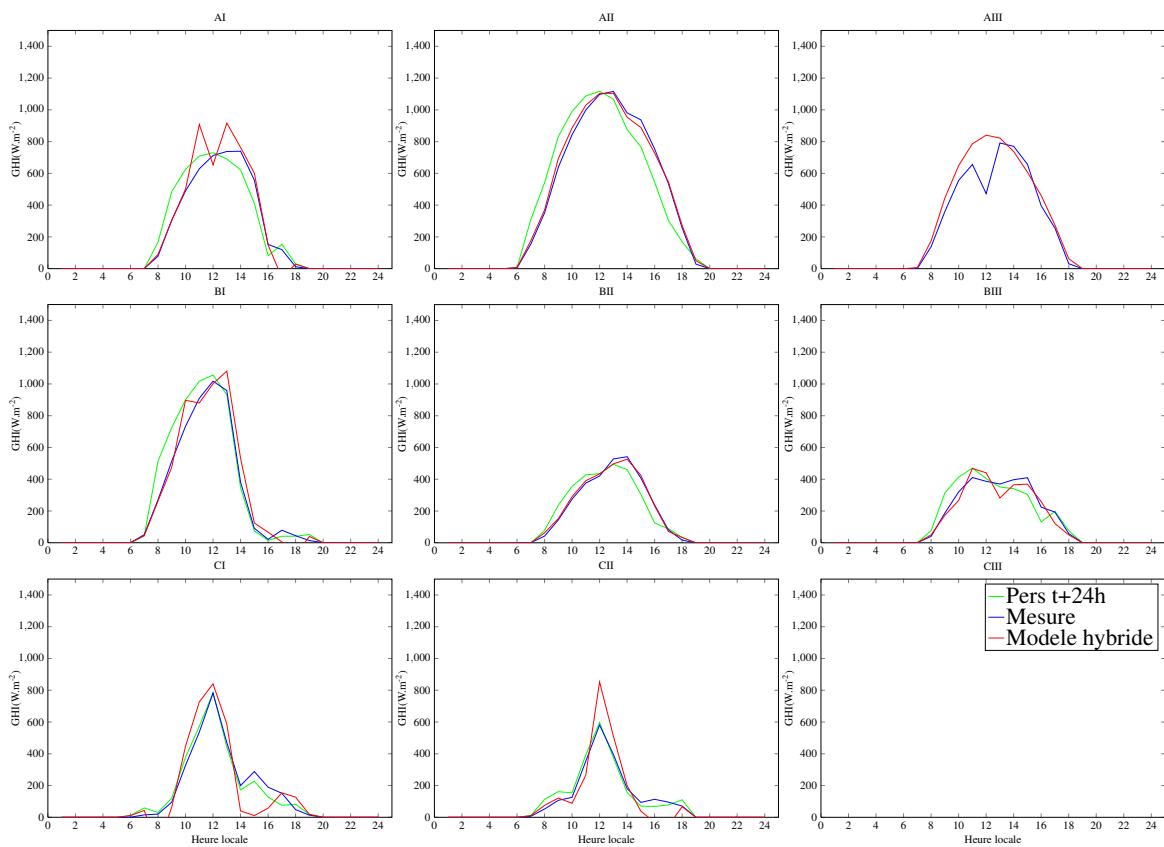


FIGURE 5.31 Exemple de prévisions multihorizon de chaque type de jour à l'horizon t+1h.



		Saint-Pierre	Tampon
RMSE	Persistence	33.5%	55.46%
	Kalman	29.4%	49.62%
MBE	Persistence	0.8%	2.8%
	Kalman	1.6%	5.1%

TABLE 5.8 Synthèse des RMSE et MBE de chaque site pour l'horizon t+1h.

## 5.5 Conclusion

Le modèle hybride de Kalman améliore la performance de prévision quelque soit l'horizon de prévision considéré.

# Conclusions

## 5.6 Conclusions

La conception de méthodes de prévision du rayonnement global à court terme et à très court terme a été abordée durant cette thèse. L'étude est basée directement sur la prévision de l'indice de clair. Les horizons de prévision varient de 5 minutes à 24 heures. Ces travaux de recherche ont été l'occasion de faire plusieurs contributions dans le domaine de la prévision photovoltaïque.

Le premier apport de cette thèse est un état de l'art des méthodes de prévision du rayonnement solaire global. Elle a permis de les classer en fonction de l'horizon de prévision et de la résolution spatiale. Par ailleurs, les méthodes hybrides ont été identifiées comme étant les plus performantes pour les prévisions à court terme et les prévisions à très court terme.

La deuxième contribution propose un modèle hybride qui combine un modèle numérique et un modèle neuronal bayésien pour produire les prévisions à court terme, c'est à dire de la veille pour le lendemain ( $J+1$ ), du rayonnement global horizontal. Cette étape a été d'une part l'occasion d'adapter le modèle numérique Weather Research and Forecasting aux spécificités des sites d'expérimentation. D'autre part, le modèle neuronal bayésien a été conçu et appliqué pour affiner les prévisions numériques. La finalité de cette partie est la production de prévisions plus performantes du rayonnement global un jour en avance. Les entrées retenues pour le modèle hybride sont la prévision du lendemain produit avec le modèle numérique WRF et l'angle solaire zénithal. Le post-traitement fait à travers le réseau de neurones bayésien produit une prévision du biais. Ainsi, les prévisions initiales du modèle numérique sont corrigées avec la sortie du modèle hybride. L'étude de performance des prévisions montre que l'hybridation apporte une amélioration à la qualité de la prévision.

La troisième contribution s'intéresse à l'amélioration des performances de prévision à très court terme. Dans cette optique, le concept d'hybridation est mis œuvre pour développer le modèle hybride de Kalman. Ce dernier combine les prévisions du modèle numérique aux mesures historiques pour produire les prévisions du rayonnement global sur des horizons

allant de 5 minutes à 3 heures. Ce modèle améliore légèrement la qualité de prévision par rapport à la technique de référence à savoir la persistance à très court terme. Par ailleurs, le modèle hybride de Kalman permet une mise en œuvre opérationnelle de la prévision.

De l'analyse de ces deux modèles hybrides de prévision du rayonnement global mis en place, il en ressort que la meilleure amélioration de la qualité de prévision est obtenue avec l'horizon J+1. Cependant, suivant le type de jour en terme de couverture nuageuse et de variabilité de l'ensoleillement, le modèle numérique sans post-traitement avec le modèle hybride peut présenter de meilleures performances de prévision. L'amélioration qu'apporte le modèle hybride de Kalman étant faible, il sera intéressant de le peaufiner dans les futurs travaux.

## 5.7 Perspectives

Les résultats de ces travaux ouvrent plusieurs pistes de recherche. Il serait intéressant d'approfondir l'exploitation du modèle numérique WRF à travers des données de forçage de meilleures résolutions. Par exemple, les prévisions du modèle numérique ECMWF pourrait être utilisé en remplacement à celles du modèles GFS. Par ailleurs, les mesures historiques pourront être formatées et incluses dans les données d'entrée du modèle WRF.

Il sera intéressant de pouvoir mieux comparer les méthodes de prévision sur tous les types de jours identifiés. Pour cela, il faudra avoir une plus grande fréquence d'apparition de tous les types de jours identifiés. Dans cette optique, il sera intéressant d'augmenter le nombre de sites d'expérimentation et la taille de la base de données des mesures historiques. Par conséquent, il faudra produire des prévisions pour des territoires qui présentent des similitudes de caractéristiques météorologiques et disposent de mesures historiques importantes. Les sites comme la Guadeloupe, la Corse, Hawaï ou encore l'Australie pourront être utilisé entre autres.

Concernant le modèle hybride de Kalman, il faudra augmenter la qualité des prévisions. Pour cela, une idée à approfondir sera de faire la combinaison linéaire de plusieurs prévisions afin d'enrichir les données d'entrées. De plus, l'information sur le type de jour qui se profile en début de journée pourra être exploiter pour mieux choisir les sources des données d'entrée.

# Bibliographie

- [1] ARRETE (2010). Arrêté du 24 novembre 2010 modifiant et complétant l'article 22 de l'arrêté du 23 avril 2008 relatif aux prescriptions techniques de conception et de fonctionnement pour le raccordement à un réseau public de distribution d'électricité en basse ou en moyenne tension d'une installation de production d'énergie électrique.
- [2] Bacher, P., Madsen, H., and Nielsen, H. A. (2009). Online short-term solar power forecasting. *Solar Energy*, 83(10) :1772 — 1783.
- [3] Badosa, J., Haeffelin, M., and Chepfer, H. (2013). Scales of spatial and temporal variation of solar irradiance on reunion tropical island. *Solar Energy*, 88(0) :42 – 56.
- [4] Baig, A., Akhter, P., and Mufti, A. (1991). A novel approach to estimate the clear day global radiation. *Renewable Energy*, 1(1) :119 — 123.
- [5] Bartlett, P. L. (1997). For valid generalization the size of the weights is more important than the size of the network. In Mozer, M. C., Jordan, M. I., and Petsche, T., editors, *Advances in Neural Information Processing Systems*, volume 9. The MIT Press.
- [6] Bird, R. E. and Riordan, C. (1986). Simple Solar Spectral Model for Direct and Diffuse Irradiance on Horizontal and Tilted Planes at the Earth's Surface for Cloudless Atmospheres. *Journal of Applied Meteorology*, 25 :87 — 97.
- [7] Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Oxford University Press, Inc., New York, NY, USA.
- [8] Bofinger, S. and Heilscher, G. (2006). "Solar electricity forecast approaches and first results". In *21st European Photovoltaic Solar Energy Conference, Dresden*, number 0, pages 4 — 8.
- [9] Boland, J. (1995). Time series analysis of climatic variables. *Solar Energy*, 55(5) :377 — 388.
- [10] Boland, J. (2008). Time series and statistical modelling of solar radiation. In *Recent Advances in Solar Radiation Modelling*, pages 283 — 312. Springer-Verlag.
- [11] Botterud, A., Zhou, Z., Wang, J., Bessa, R. J., Keko, H., Mendes, J., Sumaili, J., and Miranda, V. (2011). Use of wind power forecasting in operational decisions. Technical Report ANL/DIS-11-8, Argonne National Laboratory, East Lansing, Michigan.
- [12] Box, G. and Jenkins, G. (1970). *Time series analysis : Forecasting and control*. Holden-Day, San Francisco.

- [13] Box, G. E. P. and Jenkins, G. M. (1994). *Time Series Analysis : Forecasting and Control*. Prentice Hall PTR, Upper Saddle River, NJ, USA, 3rd edition.
- [14] Cao, J. and Cao, S. (2006). Study of forecasting solar irradiance using neural networks with preprocessing sample data by wavelet analysis. *Energy*, 31(15) :3435 — 3445.
- [15] Cao, J. and Lin, X. (2008a). Application of the diagonal recurrent wavelet neural network to solar irradiation forecast assisted with fuzzy technique. *Engineering Applications of Artificial Intelligence*, 21(8) :1255 — 1263.
- [16] Cao, J. and Lin, X. (2008b). Study of hourly and daily solar irradiation forecast using diagonal recurrent wavelet neural networks. *Energy Conversion and Management*, 49(6) :1396 — 1406.
- [17] Cao, S. and Cao, J. (2005). Forecast of solar irradiance using recurrent neural networks combined with wavelet analysis. *Applied Thermal Engineering*, 25(2005) :161 — 172.
- [18] Chen, F. and Dudhia, J. (2001). Coupling an advanced land surface–hydrology model with the penn state–ncar mm5 modeling system. part i : Model implementation and sensitivity. *Mon. Wea. Rev.*, 129(4) :569–585.
- [19] Chow, C. W., Urquhart, B., Lave, M., Dominguez, A., Kleissl, J., Shields, J., and Washom, B. (2011). Intra–hour forecasting with a total sky imager at the uc san diego solar energy testbed. *Solar Energy*, 85(11) :2881 — 2893.
- [20] Dambreville, R., Blanc, P., Chanussot, J., and Boldo, D. (2014). Very short term forecasting of the global horizontal irradiance using a spatio-temporal autoregressive model. *Renewable Energy*, 72(0) :291 – 300.
- [21] David, M., Diagne, M., and Lauret, P. (2012). Outputs and error indicators for solar forecasting models. In *Proceedings of the World Renewable Energy Forum 2012 (WREF 2012)*, Denver, USA.
- [22] Diagne, M., David, M., Lauret, P., Boland, J., and Schmutz, N. (2013). Review of solar irradiance forecasting methods and a proposition for small–scale insular grids. *Renewable and Sustainable Energy Reviews*, 27(0) :65 — 76.
- [23] Dreyfus, G., Martinez, J., Samuelides, M., Gordon, M., Badran, F., and Thiria, S. (2008). *Apprentissage statistique : Réseaux de neurones – Cartes topologiques – Machines à vecteurs supports*. Algorithmes. Eyrolles.
- [24] Dudhia, J. (1989). Numerical Study of Convection Observed during the Winter Monsoon Experiment Using a Mesoscale Two–Dimensional Model. *J. Atmos. Sci.*, 46(20) :3077–——–3107.
- [25] Galanis, G., Louka, P., Katsafados, P., Kallos, G., and Pytharoulis, I. (2006). Applications of kalman filters based on non–linear functions to numerical weather predictions. *Annals of Geophysics*, 24 :2451 — 2460.
- [26] GIEC (2007). *Contribution du Groupe de travail I, II, III au quatrième Rapport d'évaluation du GIEC*. Groupe d'experts intergouvernemental sur l'évolution du climat (GIEC).

- [27] Grell, G., Dudhia, J., and Stauffer, D. (1995). A description of the fifth-generation penn state/ncar mesoscale model (mm5). Technical Report 03.
- [28] Guarneri, R., Martins, F., and Pereira, E. (2008). Solar radiation forecast using artificial neural networks. *National Institute for Space Research*, pages 1—34.
- [29] Hammer, A., Heinemann, D., Lorenz, E., and Lucke, B. (1999). Short-term forecasting of solar radiation : a statistical approach using satellite data. *Solar Energy*, 67(1–3) :139 — 150.
- [30] Hansen, B. E. (1995). Time series analysis james d. hamilton princeton university press, 1994. *Econometric Theory*, 11(03) :625—630.
- [31] Heinemann, D., Lorenz, E., and Girodo, M. (2006). Forecasting of solar radiation. In *Solar Energy Resource Management for Electricity Generation from Local Level to Global Scale*, pages 223—233. Nova Science Publishers.
- [32] Henderson, R. (1995). Job scheduling under the portable batch system. In Feitelson, D. and Rudolph, L., editors, *Job Scheduling Strategies for Parallel Processing*, volume 949 of *Lecture Notes in Computer Science*, pages 279–294. Springer Berlin / Heidelberg.
- [33] Hocaoglu, F. O., Gerek, O. N., and Kurban, M. (2008). Hourly solar radiation forecasting using optimal coefficient 2–d linear filters and feed–forward neural networks. *Solar Energy*, 82(8) :714 — 726.
- [34] Hoff, T. E. and Perez, R. (2012). Modeling {PV} fleet output variability. *Solar Energy*, 86(8) :2177 – 2189. Progress in Solar Energy 3.
- [35] Hong, S.-Y., Dudhia, J., and Chen, S.-H. (2004). A Revised Approach to Ice Microphysical Processes for the Bulk Parameterization of Clouds and Precipitation. *Monthly Weather Review*, 132(1) :103—120.
- [36] Hong, S.-Y., Noh, Y., and Dudhia, J. (2006). A New Vertical Diffusion Package with an Explicit Treatment of Entrainment Processes. *Mon. Wea. Rev.*, 134(9) :2318—2341.
- [37] Hornik, K., Stinchcombe, M., and White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5) :359 — 366.
- [38] Hornik, K., Stinchcombe, M., White, H., and Auer, P. (1994). Degree of approximation results for feedforward networks approximating unknown mappings and their derivatives. *Neural Computation*, 6(6) :1262—1275.
- [39] Huang, J., Korolkiewicz, M., Agrawal, M., and Boland, J. (2013). Forecasting solar radiation on an hourly time scale using a coupled autoregressive and dynamical system (cards) model. *Solar Energy*, (in press).
- [40] IEA (2010). World energy outlook 2010. *International Energy Agency*.
- [41] Ineichen, P. (2006). Comparison of eight clear sky broadband models against 16 independent data banks. *Solar Energy*, 80(4) :468 — 478.
- [42] J. Remund, R. P. and Lorenz, E. (2008). Comparison of solar radiation forecasts for the usa. *Proc.23rd European Photovoltaic Solar Energy Conference*, 2 :3—5.

- [43] Ji, W. and Chee, K. C. (2011). Prediction of hourly solar radiation using a novel hybrid model of arma and tdnn. *Solar Energy*, 85(5) :808 — 817.
- [44] Kain, J. S. (2004). The kain–fritsch convective parameterization : An update. *Journal of Applied Meteorology*, 43(1) :170—181.
- [45] Kalman, R. E. (1960). A new approach to linear filtering and prediction problems. *Transactions of the ASME – Journal of Basic Engineering*, (82 (Series D)) :35—45.
- [46] Kaplanis, S. (2006). New methodologies to estimate the hourly global solar radiation ; comparisons with existing models. *Renewable Energy*, 31(6) :781 — 790.
- [47] Kemmoku, Y., Orita, S., Nakagawa, S., and Sakakibara, T. (1999). Daily insolation forecasting using a multi–stage neural network. *Solar Energy*, 66(3) :193 — 199.
- [48] Lafore, J. P., Stein, J., Asencio, N., Bougeault, P., Ducrocq, V., Duron, J., Fischer, C., Hérel, P., Mascart, P., Masson, V., Pinty, J. P., Redelsperger, J. L., Richard, E., and Vilà–Guerau de Arellano, J. (1998). The meso–nh atmospheric simulation system. part i : adiabatic formulation and control simulations. *Annales Geophysicae*, 16(1) :90—109.
- [49] Lara–Fanego, V., Ruiz–Arias, J. A., Pozo–Vazquez, D., Santos–Alamillos, F. J., and Tovar–Pescador, J. (2012). Evaluation of the wrf model solar irradiance forecasts in andalusia (southern spain). *Solar Energy*, 86(8) :2200 — 2217. Progress in Solar Energy 3.
- [50] Lauret, P., Fock, E., Randrianarivony, R. N., and Manicom–Ramsamy, J.-F. (2008). Bayesian neural network approach to short time load forecasting. *Energy Conversion and Management*, 49(5) :1156 — 1166.
- [51] Lawrence, S., Giles, C. L., and Tsoi, A. C. (1997). Lessons in neural network training : Overfitting may be harder than expected. In *In Proceedings of the Fourteenth National Conference on Artificial Intelligence, AAAI-97*, pages 540–545. AAAI Press.
- [52] LOI (2010). Loi numéro 2009967 du 3 août 2009 de programmation relative à la mise en œuvre du grenelle de l’environnement (1).
- [53] Lorenz, E., Hammer, A., and Heinemann, D. (2004). Short term forecasting of solar radiation based on satellite data. In *EUROSUN2004 (ISES Europe Solar Congress)*, pages 841 — 848.
- [54] Lorenz, E. and Heinemann, D. (2012). 1.13 - prediction of solar irradiance and photovoltaic power. In in Chief : Ali Sayigh, E., editor, *Comprehensive Renewable Energy*, pages 239 — 292. Elsevier, Oxford.
- [55] Lorenz, E., Heinemann, D., and Kurz, C. (2011a). Local and regional photovoltaic power prediction for large scale grid integration : Assessment of a new algorithm for snow detection. *Progress in Photovoltaics : Research and Applications*, pages n/a—n/a.
- [56] Lorenz, E., Heinemann, D., and Wickramaratne, H. (2007). Forecast of ensemble power production by grid–connected PV systems. *Proc. 20th European PV*.

- [57] Lorenz, E., Hurka, J., Heinemann, D., and Beyer, H. G. (2009a). Irradiance Forecasting for the Power Prediction of Grid-Connected Photovoltaic Systems. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2(1) :2—10.
- [58] Lorenz, E., Remund, J., Muller, S., Traunmuller, W., Steinmaurer, G., D., Ruiz-Arias, J., Fanego, V., Ramirez, L., Romeo, M., Kurz, C., Pomares, L., and Guerrero, C. (2009b). Benchmarking of different approaches to forecast solar irradiance. In *24th European Photovoltaic Solar Energy Conference*.
- [59] Lorenz, E., Scheidsteger, T., Hurka, J., Heinemann, D., and Kurz, C. (2011b). Regional pv power prediction for improved grid integration. *Progress in Photovoltaics : Research and Applications*, 19(7) :757—771.
- [60] Lucheroni, C. (2009). A resonating model for the power market and its calibration. *SSRN* : <http://ssrn.com/abstract=1850469>.
- [61] Lucia, U. (2013). Entropy and exergy in irreversible renewable energy systems. *Renewable and Sustainable Energy Reviews*, 20(0) :559 — 564.
- [62] MacKay, D. J. C. (1992). A practical bayesian framework for backpropagation networks. *Neural Computation*, 4(3) :448—472.
- [63] Mackay, D. J. C. (2003). *Information Theory, Inference and Learning Algorithms*. Cambridge University Press, first edition edition.
- [64] Mathiesen, P. and Kleissl, J. (2011). Evaluation of numerical weather prediction for intra-day solar forecasting in the continental united states. *Solar Energy*, 85(5) :967 — 977.
- [65] Maxwell, E., Wilcox, S., and Rymes, M. (1993). Users manual for seri qc software, assessing the quality of solar radiation data. *Report no. NREL-TP-463-5608*. 1617 Cole Boulevard, Golden, CO : National Renewable Energy Laboratory.
- [66] Mellit, A., Benghane, M., and Kalogirou, S. (2006). An adaptive wavelet-network model for forecasting daily total solar-radiation. *Applied Energy*, 83(7) :705 — 722.
- [67] Mellit, A. and Kalogirou, S. A. (2008). Artificial intelligence techniques for photovoltaic applications : A review. *Progress in Energy and Combustion Science*, 34(5) :574 — 632.
- [68] Mellit, A. and Pavan, A. M. (2010). A 24-h forecast of solar irradiance using artificial neural network : Application for performance prediction of a grid-connected pv plant at trieste, italy. *Solar Energy*, 84(5) :807 — 821.
- [69] Mihalakakou, G., Santamouris, M., and Asimakopoulos, D. N. (2000). The total solar radiation time series simulation in Athens, using neural networks. *Theoretical and Applied Climatology*, 66(3-4) :185—197.
- [70] Mlawer, E. J., Taubman, S. J., Brown, P. D., Iacono, M. J., and Clough, S. A. (1997). Radiative transfer for inhomogeneous atmospheres : Rrtm, a validated correlated-k model for the longwave. *Journal of Geophysical Research : Atmospheres*, 102(D14) :16663—16682.



- [71] Monin, A. S. and Obukhov, A. M. (1954). Basic laws of turbulent mixing in the surface layer of the atmosphere. *Contrib. Geophys. Inst. Acad. Sci.*, 151 :163—187.
- [72] Monteiro, C., Keko, H., Bessa, R., Miranda, V., Botterud, A., Wang, J., , and Conzelmann, G. (2009). A quick guide to wind power forecasting : State-of-the-art 2009. Technical Report ANL/DIS-10-2, Argonne National Laboratory, East Lansing, Michigan.
- [73] NCEP (2012). National centers for environmental prediction (ncep) <http://www.nco.ncep.noaa.gov/pmb/products/gfs/>. (*web site*).
- [74] NCL (2013). The ncar command language (version 6.1.2). [*Software*].
- [75] OER (2013). Bilan énergétique de l'île de la réunion 2012 –version technique. *Observatoire Énergie Réunion*.
- [76] Paulson, C. (1970). The mathematical representation of wind speed and temperature profiles in the unstable atmospheric surface layer. *Journal of Applied Meteorology*, 9 :857—861.
- [77] Pelland, S., Galanis, G., and Kallos, G. (2011). Solar and photovoltaic forecasting through post-processing of the global environmental multiscale numerical weather prediction model. *Progress in Photovoltaics : Research and Applications*, pages n/a—n/a.
- [78] Perez, R., Beauharnois, M., Lorenz, E., Pelland, S., and Schlemmer, J. (2011). Evaluation of numerical weather prediction solar irradiance forecasts in the us. ASES Annual Conference. Raleigh, NC, USA, 17–21 May.
- [79] Perez, R., Kivalov, S., Schlemmer, J., Jr., K. H., Renné, D., and Hoff, T. E. (2010). Validation of short and medium term operational solar radiation forecasts in the us. *Solar Energy*, 84(12) :2161 — 2172.
- [80] Perez, R., Moore, K., Wilcox, S., Renné, D., and Zelenka, A. (2007). Forecasting solar radiation preliminary evaluation of an approach based upon the national forecast database. *Solar Energy*, 81(6) :809 — 812.
- [81] Praene, J. P., David, M., Sinama, F., Morau, D., and Marc, O. (2012). Renewable energy : Progressing towards a net zero energy island, the case of reunion island. *Renewable and Sustainable Energy Reviews*, 16(1) :426 — 442.
- [82] Reikard, G. (2009). Predicting solar radiation at high resolutions : A comparison of time series forecasts. *Solar Energy*, 83(3) :342 — 349.
- [83] Rigollier, C., Lefèvre, M., and Wald, L. (2004). The method heliosat-2 for deriving shortwave solar radiation from satellite images. *Solar Energy*, 77(2) :159 — 169.
- [84] Seity, Y., Brousseau, P., Malardel, S., Hello, G., Bénard, P., Bouttier, F., Lac, C., and Masson, V. (2011). The AROME-France Convective-Scale Operational Model. *Monthly Weather Review*, 139 :976—991.

- [85] Sfetsos, A. and Coonick, A. (2000). Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques. *Solar Energy*, 68(2) :169 –– 178.
- [86] Skamarock, W., Klemp, J., Dudhia, J., and al (2008). A description of the advanced research wrf version 3. *Technical Note NCAR/TN–475+STR*. Boulder, CO : *Mesoscale and Microscale Meteorology Division, National Center for Atmospheric Research*.
- [87] Tewari, M., Chen, F., Wang, W., Dudhia, J., Lemone, M., Mitchell, K., Ek, M., Gayno, G., Wegiel, J., and Cuenca, R. (2004). Implementation and verification of the unified noah land–surface model in the wrf model. *20th Conference on Weather Analysis and Forecasting/16th Conference on Numerical Weather Prediction, Seattle, WA, American Meteorological Society*, pages 11 –– 15.
- [88] USGS (2012). United states geological survey, technical report u.s. geological survey <http://www.usgs.gov>. (*web site*).
- [89] V. Kostylev, A. P. (2011). Solar power forecasting performance – towards industry standards. *1st International Workshop on the Integration of Solar Power into Power Systems Aarhus*. Denmark, October.
- [90] Vincent, G. (Octobre,2012). Présentation edf–sei, rencontre prévision insulaire, aix–en–provence.
- [91] Wang, G., Guo, L., and Duan, H. (2013). Wavelet neural network using multiple wavelet functions in target threat assessment. *The Scientific World Journal*.
- [92] Wang, W., Bruyère, C., Duda, M., Dudhia, J., Gill, D., and chuan Lin, H. (2012). Arw version 3 modelling system user’s guide.



# Annexe A

## Filtre de Kalman linéaire

Cette section présente dans un premier temps l'intérêt du modèle espace-état. La deuxième partie aborde l'algorithme général du filtre de Kalman linéaire utilisé pour estimer les variables cachées et les paramètres.

### A.1 Modèle espace-état

L'intérêt d'utiliser un modèle espace-état pour prévoir une série temporelle, par rapport aux techniques classiques développées par Box et Jenkins [12], repose sur trois points. D'abord, les besoins de stationnarité<sup>1</sup> et de racine unitaire nécessaire à l'utilisation d'un modèle ARMA sont éliminés d'autant plus que les résultats du filtre de Kalman restent valides en présence de séries non-stationnaires. Ensuite, le cadre espace-état permet de supprimer l'hypothèse d'une distribution gaussienne pour les bruits. Enfin, les coefficients du modèle peuvent évoluer et ne sont pas obligatoirement considérés comme invariants au cours de la période d'estimation.

De manière simplifiée, le modèle espace-état s'appuie sur les concepts de variable observée et variable cachée. La variable observée correspond au signal et la variable cachée représente l'état interne. Ainsi, le modèle espace-état est constitué d'une équation de mesure et d'une équation d'état. L'équation de mesure (A.1) décrit la manière dont les variables observées sont générées par les variables cachées et les résidus. L'équation d'état (A.2) décrit la génération des variables cachées à partir de leurs retard et innovation. Le modèle espace-

---

1. Au sens faible du terme, la notion de **stationnarité** correspond au cas où l'espérance mathématique  $E(X_t)$ , la variance  $V(X_t)$  et les auto-covariances  $Cov(X_t, X_{t+h})$  de la série  $X_t$  sont indépendantes du temps.

état du processus multivarié  $y_t$  est représenté par les équations suivantes :

$$x_{t+1} = \mathbb{M}_t x_t + \varepsilon_t \quad (\text{A.1})$$

$$y_t = \mathbb{H}_t x_t + \eta_t \quad (\text{A.2})$$

$$x(t_0) = x_0 + \mu \quad (\text{A.3})$$

- $y_t$  est la variable de mesure et  $x_t$  est la variable d'état ;
- $\varepsilon_t$  est le bruit d'innovations et représente l'erreur de la modélisation ;
- $\eta_t$  le vecteur des erreurs de mesure et correspond à l'erreur sur la mesure du signal ;
- $\mathbb{M}_t$  est la matrice de transition et  $\mathbb{H}_t$  est la matrice de mesure ;
- $\mathbb{H}_t x_t$  est le signal.

Dans une mise en oeuvre pratique,  $\eta_t$  est calculé à l'aide de la précision des différents capteurs et  $\varepsilon_t$  est déterminé par les perturbations affectant le système dynamique.

Cependant, la représentation espace-état associée au processus  $y_t$  n'est pas unique car diverses dimensions du vecteur d'état sont possibles. Donc il convient de rechercher un modèle de dimension optimale, de manière à ne pas alourdir la procédure d'estimation. Pour simplifier cette dernière, les hypothèses A.1.1 sont retenues.

#### **Hypothèses A.1.1** –

- les équations de mesure et d'état sont linéaires ;
- les bruits d'observation et d'innovation sont des bruits blanc<sup>2</sup> ;
- les variables cachées suivent à un instant initial donné une loi gaussienne.
- les bruits d'observation et d'innovation sont indépendants (condition d'inversibilité)
- la variable cachée initiale et ces bruits sont indépendants (condition de causalité)

## **A.2 Filtre de Kalman**

Depuis 1960, le filtre de Kalman [45] est utilisé dans diverses applications, et a donné lieu à de nombreuses recherches. C'est un processus itératif basé sur un schéma de prédiction - correction par la mesure. Le filtre de Kalman permet de résoudre de manière optimale le problème du filtrage linéaire quand les bruits du système sont additifs et gaussiens. La meilleure estimation de  $x_t$  sachant les données jusqu'à l'instant  $t$  est donnée par l'espérance conditionnelle  $\hat{x}_t$  et sa covariance  $B_t$  avec  $\hat{x}_t = \mathbb{E}[x_t | y_0, \dots, y_t]$  et  $B_t = \mathbb{E}[(x_t \hat{x}_t)(x_t \hat{x}_t)^T]$ . Leurs

---

2. Un bruit blanc (au sens faible) est un processus aléatoire d'espérance et d'auto-covariances nulles, dont la distribution n'est pas toujours supposée gaussienne.

moments sont calculés par le filtre de Kalman de manière récursive. Comme  $x_t|y_0, \dots, y_t$  suit une loi gaussienne, ces deux moments définissent entièrement la distribution de probabilité.

Le principe du filtre de Kalman est d'estimer à chaque instant  $t$  le vecteur d'état  $x_t \in \mathbb{R}^n$ , connaissant des observations  $y_t \in \mathbb{R}^m$  observée jusqu'à la date  $t$ , avec  $\hat{x}_t = E(x_t|y_0, \dots, y_t)$ ,  $t = 1, \dots, T$ . Cet algorithme consiste à itérer les équations de (A.6) à (A.8).

$$\hat{x}_t = \hat{x}_{t|t-1} + K_t(y_t - \mathbb{H}_t \hat{x}_{t|t-1}) \quad (\text{A.4})$$

$$B_t = B_{t|t-1} - K_t \mathbb{H}_t B_{t|t-1} \quad (\text{A.5})$$

$$\hat{x}_{t+1|t} = \mathbb{M}_t \hat{x}_t \quad (\text{A.6})$$

$$\mathbb{B}_{t+1|t} = Q_t + \mathbb{M}_t B_t \mathbb{M}_t^T \quad (\text{A.7})$$

$$K_t = B_{t|t-1} \mathbb{H}_t^T (R_t + \mathbb{H}_t B_{t|t-1} \mathbb{H}_t^T)^{-1} \quad (\text{A.8})$$

- $\hat{x}_t = E(x_t|y_0, \dots, y_t)$  est l'estimation courante du vecteur d'état ;
- $\hat{x}_{t+1|t} = E(x_{t+1}|y_0, \dots, y_t)$  est la prévision de  $x_t$  de l'instant  $t + 1$  à  $t$  ;
- $\mathbb{B}_{t+1|t} = V(x_t - x_{t+1|t})$  est la variance de l'erreur de prévision de l'instant  $t + 1$  à  $t$  ;

Les équations (A.4) et (A.5) représentent la phase prédiction. Elles mettent à jour l'estimation de la variable d'état en  $t + 1$  à partir de l'équation d'état. Les équations (A.6) à (A.8) représentent la phase de correction.

La matrice  $K_t$ , définie par l'équation (A.8), est le gain du filtre de Kalman. Durant la phase de correction, ce gain  $K_t$  est multiplié à l'innovation  $y_t - \mathbb{H}_t \hat{x}_{t|t-1}$  qui est la différence entre la mesure observée et la mesure prédite. L'innovation permet de corriger l'estimée prédite. L'interprétation de cette phase de correction se présente ainsi :

- une grande confiance dans les estimations précédentes ( $B_{t|t-1}$  “faible”) et un doute dans les mesures ( $R_t$  “élevé”) impliquent un gain faible. Par conséquent, la prédiction est faiblement corrigée ;
- Un doute sur les estimations précédentes et une confiance à la nouvelle mesure entraînent un gain fort. Donc la mesure prend de l'importance dans la valeur finale de l'estimé.

Les équations (A.4) et (A.5) actualisent respectivement l'estimation de  $x_t$  et sa précision. L'estimation courante du vecteur d'état dans l'équation (A.4) est obtenue à partir de l'estimation faite à la date  $t - 1$ , à laquelle on ajoute un terme prenant en compte l'information nouvelle contenue dans l'observation de  $y_t$  ; ce terme, qui se déduit d'un programme de minimisation de la variance de l'erreur courante, s'exprime simplement en fonction de l'estimation à la date  $t - 1$  de  $x_t$ , de la variable de mesure  $y_t$ , et de la matrice de gain  $K_t$ .

Les enchaînements des phases de prédiction et de correction sont illustrés par la Figure A.1.

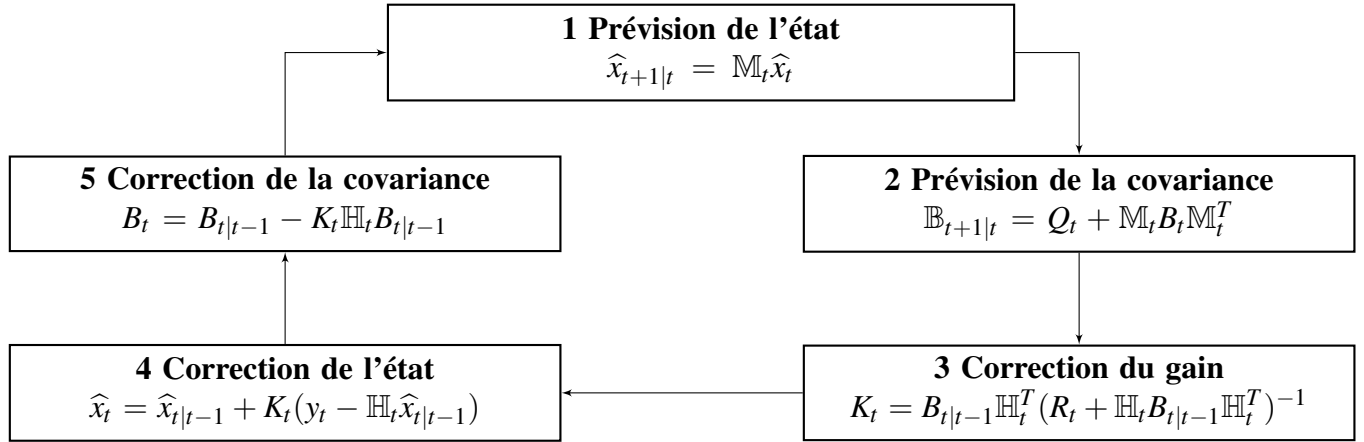


FIGURE A.1 Algorithme du filtre de Kalman [77]

L'initialisation de l'algorithme nécessite la connaissance de la condition initiale  $x_0$  de covariance  $B_0$ . Il faut donc avoir un a priori sur  $x_0$  pour que le processus converge.

# Annexe B

## Publications

### B.1 Publications en revue internationale

- **Maimouna Diagne**, Mathieu David, John Boland, Nicolas Schmutz, and Philippe Lauret. Post- processing of solar irradiance forecasts from WRF model at reunion island. *Solar Energy*, 105(0) :99 108, 2014.
- **Maimouna Diagne**, Mathieu David, Philippe Lauret, John Boland, and Nicolas Schmutz. Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. *Renewable and Sustainable Energy Reviews*, 27(0) :65 76, 2013.

### B.2 Publications en conférence internationale

- **Maimouna Diagne**, Mathieu David, John Boland, Nicolas Schmutz, and Philippe Lauret. Post-processing of solar irradiance forecasts from wrf model at reunion island. In *Proceedings of ISES Solar World Congress (SWC 2013)*, Cancun, Mexico, 2013.
- **Maimouna Diagne**, Mathieu David, Philippe Lauret, and John Boland. Solar irradiation forecasting : state-of-the-art and proposition for future developments for small-scale insular grids. In *Proceedings of the World Renewable Energy Forum 2012 (WREF 2012)*, Denver, USA, May 2012.
- Mathieu David, **Maimouna Diagne**, and Philippe Lauret. Outputs and error indicators for solar forecasting models. In *Proceedings of the World Renewable Energy Forum 2012 (WREF 2012)*, Denver, USA, May 2012.



- Philippe Lauret, Auline Rodler, Marc Muselli, **Maimouna Diagne**, Mathieu David, and Cyril Voyant. A bayesian committee model approach to forecasting global solar radiation. In *Proceedings of the World Renewable Energy Forum 2012 (WREF 2012)*, Denver, USA, May 2012.