

UNIVERSITÉ DE MONTRÉAL

**HYDRO-CLIMATOLOGIE GLOBALE
POUR LA PRÉVISION DES CRUES DU NIL
AU MOYEN DE FONCTIONS DE TRANSFERT AVEC BRUIT
ET DE RÉSEAUX DE NEURONES ARTIFICIELS**

AYMAN GEORGES AWADALLAH
DÉPARTEMENT DES GÉNIES CIVIL, GÉOLOGIQUE ET DES MINES
ÉCOLE POLYTECHNIQUE DE MONTRÉAL

THÈSE PRÉSENTÉE EN VUE DE L'OBTENTION
DU DIPLÔME DE PHILOSOPHIAE DOCTOR (Ph.D.)
(GÉNIE CIVIL)
SEPTEMBRE 1999



**National Library
of Canada**

**Acquisitions and
Bibliographic Services**

**395 Wellington Street
Ottawa ON K1A 0N4
Canada**

**Bibliothèque nationale
du Canada**

**Acquisitions et
services bibliographiques**

**395, rue Wellington
Ottawa ON K1A 0N4
Canada**

Your file Votre référence

Our file Notre référence

The author has granted a non-exclusive licence allowing the National Library of Canada to reproduce, loan, distribute or sell copies of this thesis in microform, paper or electronic formats.

The author retains ownership of the copyright in this thesis. Neither the thesis nor substantial extracts from it may be printed or otherwise reproduced without the author's permission.

L'auteur a accordé une licence non exclusive permettant à la Bibliothèque nationale du Canada de reproduire, prêter, distribuer ou vendre des copies de cette thèse sous la forme de microfiche/film, de reproduction sur papier ou sur format électronique.

L'auteur conserve la propriété du droit d'auteur qui protège cette thèse. Ni la thèse ni des extraits substantiels de celle-ci ne doivent être imprimés ou autrement reproduits sans son autorisation.

0-612-48877-2

Canada

UNIVERSITÉ DE MONTRÉAL

ÉCOLE POLYTECHNIQUE DE MONTRÉAL

Cette thèse intitulée :

**HYDRO-CLIMATOLOGIE GLOBALE
POUR LA PRÉVISION DES CRUES DU NIL
AU MOYEN DE FONCTIONS DE TRANSFERT AVEC BRUIT
ET DE RÉSEAUX DE NEURONES ARTIFICIELS**

présentée par: AWADALLAH Ayman Georges

en vue de l'obtention du diplôme de: Philosophiae Doctor

a été dûment acceptée par le jury d'examen constitué de:

M. CLÉMENT Bernard, Ph.D., président

M. ROUSSELLE Jean, Ph.D., membre et directeur de recherche

M. ROBERT Benoît, Ph.D., membre et co-directeur de recherche

M. LEFEBVRE Mario, Ph.D., membre

M. DELLEUR Jacques W., D.Eng., examinateur externe

À la mémoire de mes parents qui m'ont fait confiance
et m'ont appris le sens de l'engagement
À mon épouse et ma meilleure amie qui partage ma vie
À ma fille qui anime mon goût de vivre
À ma sœur qui se réjouit à mes joies et partage mes peines
À tous mes professeurs qui m'ont orienté vers la recherche
À tous les chercheurs qui ont travaillé sur le Nil

REMERCIEMENTS

Je tiens à remercier vivement mes directeurs de recherche, le professeur Jean Rousselle ing., Ph.D., et le professeur Benoît Robert ing., Ph.D., qui ont accepté de diriger ma thèse. Je suis très reconnaissant, tout d'abord, au professeur Rousselle, qui par ses précieux conseils académiques et non académiques, par son soutien, par son sens de l'humour et son insistance, m'a permis de mener à bien mes études et de respecter mon échéancier serré. Je suis aussi reconnaissant au professeur Robert qui m'a beaucoup aidé à définir mon sujet de recherche et m'a beaucoup soutenu, sur le plan personnel, par son enthousiasme et sa disponibilité.

Je remercie également les autres membres du jury : le professeur Bernard Clément, Ph.D., le professeur Mario Lefebvre, Ph.D., et le professeur Jacques W. Delleur, D.Eng., qui non seulement ont accepté de juger cette thèse, mais qui ont donné de leur temps et efforts pour m'accompagner depuis mon examen de synthèse à travers maintes réunions d'évaluation, contacts et correspondances qui ont souvent guidé ma recherche. Je remercie aussi le professeur Roland Malhamé ing., Ph.D., pour avoir accepté d'être représentant du doyen à ma soutenance.

Je témoigne de ma gratitude à l'Agence Canadienne pour le Développement International qui a financé mes études doctorales à travers le Programme Canadien des Bourses de la Francophonie. Je remercie sincèrement mes responsables du suivi pédagogique de ce programme de bourses : Madame Micheline Roberge et Monsieur Denis Breton. Je suis aussi gré au ministère des Travaux Publics et Ressources Hydriques, du Caire, en Égypte, qui a fourni les données des débits mensuels du Nil, et au *United Kingdom Meteorological Office*, d'Angleterre, qui a fourni les données de températures de surface de l'océan, données qui ont servi dans ce travail de recherche.

Je tiens à remercier sincèrement tous les professeurs et chercheurs à travers le monde avec qui j'ai eu des contacts durant mes études et qui m'ont fourni des documents ou qui m'ont orienté vers des publications ou des personnes ressources. Un

remerciement spécial est dû au professeur Elfatih Eltahir, du Massachusetts Institute of Technology, qui a accepté de me rencontrer deux fois à Boston et à Québec, et aux professeurs Marc Moore, de l'École Polytechnique, et Bawan Singh, du département de géographie, de l'université de Montréal, pour leurs commentaires et suggestions, durant la préparation d'une publication issue de ce travail de recherche. Je n'oublie pas non plus les professeurs de la section d'hydraulique, du département des génies civil, géologique et des mines, pour leurs conseils et leurs encouragements.

Je remercie tous mes collègues de travail avec qui j'ai partagé les hauts et les bas au cours des années d'études. Je suis spécialement très reconnaissant aux Docteurs Noël Dacruz Évora et Salvator Birikundavyi, associés de recherche, qui ont été très présents aussi bien sur le plan académique, par leurs suggestions et commentaires pertinents, qu'au niveau personnel, par leur amitié et leur soutien indéfectible, tout au long de mes études.

Je remercie aussi le personnel de l'École Polytechnique et du département des génies civil, géologique et des mines, spécialement monsieur André Lacombe, dessinateur au département à qui je dois la bonne présentation des figures des chapitres II et IV de cette thèse, ainsi que les employés des bibliothèques de l'École Polytechnique et de l'Université de Montréal, qui m'ont beaucoup aidé dans ma recherche bibliographique.

Enfin, je ne saurais terminer sans avoir une pensée affectueuse pour mon épouse, qui était bien compréhensive et aidante et qui a accepté beaucoup de sacrifices surtout à l'étape ultime de la rédaction de cette thèse, et pour ma fille qui, par son sourire et son émerveillement, anime quotidiennement mon goût de vivre. Une pensée spéciale est aussi pour ma sœur qui a su, même à distance, m'encourager. Je remercie aussi toute ma famille et mes amis, à la fois en Égypte, au Canada et ailleurs, qui m'ont témoigné beaucoup d'enthousiasme, de gentillesse et de disponibilité, tout au long de mes études doctorales.

RÉSUMÉ

Cette thèse traite de la modélisation statistique / stochastique de la téléconnexion entre les apports naturels, qui proviennent des précipitations en régions tropicales, et les indices de la variabilité climatique. Le but, poursuivi tout au long de ce présent travail de recherche, est de mettre au point des modèles de prévision du volume cumulatif des apports naturels qui entrent dans un grand réservoir, soit celui du Haut Barrage d'Assouan (HBA) situé sur le Nil en Égypte. Deux modèles de prévision des débits ont été construits : le premier est basé sur les fonctions de transfert avec bruit (FTB) et le second sur les réseaux de neurones artificiels (RNA). Les entrées des modèles sont les températures de surface de l'océan (TSO) dans des régions déterminées ainsi que les volumes cumulatifs des apports naturels des années antérieures. La prévision se fait trois mois avant l'occurrence de la pointe de la crue, afin de permettre une meilleure planification des prochains prélèvements mensuels faits à partir du réservoir.

Les résultats obtenus grâce aux modèles présentés dans cette thèse sont fort satisfaisants et nettement supérieurs à ceux obtenus par les modèles antérieurs et présentement utilisés. Les modèles parviennent à expliquer 63% de la variation des débits, avec des coefficients de corrélation qui excèdent 0,85 entre les débits prédits et les débits observés, ainsi que des erreurs relatives de 6% en moyenne. Comparée aux modèles de prévision publiés dans la littérature qui n'expliquent que 36% de la variabilité de la crue du Nil, cette performance élevée de nos modèles est due à deux aspects innovateurs de cette thèse.

Le premier aspect innovateur se rapporte à un meilleur choix des prédictors de la crue qui est basé sur les études récentes en climatologie. Deux indices de la variabilité interannuelle climatique sont utilisés. Le premier est représentatif du phénomène qui couple le courant maritime El-Niño avec l'Oscillation Australe (El-Niño / Southern

Oscillation, ENSO). Le second, qui est utilisé pour la première fois dans le cadre de cette thèse, est calculé comme la moyenne des anomalies de TSO dans une région spécifique de l'océan Indien. Cet indice, qui s'est avéré un bon prédicteur de la crue du Nil, permet de raffiner les prévisions faites à l'aide d'un modèle où seul un indice de l'ENSO est utilisé comme variable exogène. D'autres indices climatiques ont été testés, mais compte tenu que leur utilisation n'améliore pas la performance des modèles en prévision, ils n'ont pas été retenus comme entrées des meilleurs modèles construits dans ce travail de recherche.

Le second aspect innovateur se rapporte au choix de modèles plus appropriés à la problématique de prévision des écoulements en utilisant les prédicteurs climatiques. Les modèles de fonctions de transfert avec bruit (FTB) et de réseaux de neurones artificiels (RNA) sont utilisés pour la première fois pour prévoir directement les écoulements à partir des indices climatiques. La performance de ces modèles en prévision est nettement supérieure à celle des modèles de régression linéaire qui sont généralement utilisés dans les études de téléconnexions entre les débits et les indices climatiques.

L'analyse des résultats des modèles proposés dans cette thèse, surtout pour les années où les modèles donnent de mauvaises prévisions, permet de comprendre la dynamique de l'interaction entre les TSO dans différentes régions et son impact sur la crue du Nil. Pour une année donnée, lorsque le signal de l'ENSO est faible et celui de l'Atlantique sud est très fort, les modèles décrits dans cette thèse ne donnent pas de bonnes prévisions. Cela se produit seulement pour 7 ans sur un total de 70 années disponibles, ce qui est relativement limité pour pouvoir construire un modèle statistique qui tient compte de cette discordance entre les différents océans.

La comparaison entre les fonctions de transfert avec bruit (FTB) et les réseaux de neurones artificiels (RNA) permet de tirer les deux conclusions suivantes, qui pourraient s'appliquer à de nombreuses problématiques de prévision à moyen terme des

écoulements de fleuves tropicaux. La première est que la relation entre les TSO dans l'est du Pacifique et la crue du Nil peut être approximée par une relation linéaire à un degré acceptable de précision, vu que les résultats des modèles de FTB et de RNA sont similaires. La seconde est que les modèles de FTB sont plus appropriés pour traiter le problème de la prévision à moyen terme des débits en utilisant l'information climatique. Cette dernière conclusion est due à la parcimonie des FTB, à l'existence de méthodes pour leur validation, et au nombre restreint de données disponibles. Ce dernier point désavantage la modélisation par RNA.

ABSTRACT

The principal objective of this research is to improve forecasting models of the cumulative volume of natural inflows entering the large reservoir of the High Aswan Dam, located on the Nile River in Egypt. This has been accomplished by statistical / stochastic modeling of the teleconnection between the natural inflows resulting from precipitation in tropical regions, and the indices of climatic variability. Two forecasting models have been built: the first is based on a transfer function with noise (TFN) while the second exploits artificial neural networks (ANN). Inputs to both models are the sea surface temperatures (SST) in specific regions as well as the cumulative volumes of natural inflows of previous years. The forecast is implemented with a three-month lead-time before the occurrence of the Nile flood peak; this enables a better planning of the future monthly withdrawals from the reservoir.

The results obtained from the models presented in this thesis are very satisfactory and appear to be significantly superior to those obtained from previously published or practically implemented models. The models explain up to 63% of the streamflow variability, with correlation coefficients between forecasted and observed streamflows exceeding 0.85. Mean absolute percentage errors are typically of the order of 6%. Compared to previously published models which explain only 36% of the Nile flood variability, the superior performance of the models proposed here is due mainly to two innovative aspects of the research reported in this thesis.

The first aspect is related to a better choice of the predictor of the flood, which is based on recent climatological studies. Two indices of the climatic variability are used: The first is representative of the phenomenon coupling the El-Niño ocean current with the Southern Oscillation (ENSO). The second, which for the first time has been exploited within the framework of this research, is obtained by averaging the SST

anomalies in a specific region of the Indian Ocean. The use of this variable, which turns out to be a good predictor of the Nile flood, allows the refinement of the forecasts obtained with models where only the ENSO index is used as the exogeneous variable. Other indices of the climatic variability were also tested, but none of them were retained in the best models used, since they did not improve model performance.

The second innovative aspect concerns the choice of more appropriate models related to the streamflow forecasting using climatic predictors. Transfer functions with noise (TFN) and artificial neural networks (ANN) are used for the first time to directly forecast streamflows using climatic indices. The forecasting performance of these models is markedly superior to those of linear regression models commonly used in teleconnection studies between streamflows and climatic indices.

Analysis of the results of the models proposed, especially for the years when the models provide poor forecasts, enables us to understand the dynamics of the interaction between SSTs in different regions of the globe and its impact on the Nile flood. If, for a given year, the ENSO signal is weak while the South Atlantic one is very strong, the models described in this thesis yield inaccurate forecasts. This happens infrequently, typically about 7 years out of 70. Improvement of this result would be difficult, since 7 years is a relatively small population sample with which to build a statistical model that takes into account the opposition between different oceans.

The comparison between the TFN and ANN models enables one to draw the following two conclusions, which could be applicable to several mid-range forecasting problems of tropical river streamflows. The first is that a linear assumption of the relationship between the SST in the East Pacific and the Nile flood might well be justified within an acceptable accuracy level, since the results of the TFN and ANN models are similar. The second conclusion is that the TFN model is more appropriate for mid-range streamflow forecasting using climatic information. This last conclusion is

due to the TFN parsimony, to the existence of a validation methodology for the TFN models and to the restricted quantity of available data. This last point is disadvantageous for ANN modeling.

TABLE DES MATIÈRES

DÉDICACE	iv
REMERCIEMENTS	v
RÉSUMÉ	vii
ABSTRACT	x
TABLE DES MATIÈRES	xiii
Liste des tableaux	xviii
Liste des figures	xix
Liste des sigles et abréviations	xxiv

Chapitre I

INTRODUCTION.....	1
-------------------	---

Chapitre II

DESCRIPTION, MODÉLISATION

ET PRÉVISION HYDROLOGIQUES DU NIL	6
2.1 Introduction	6
2.2 Corne de l'Afrique : description	8
2.2.1 Description générale	8
2.2.2 Champs atmosphériques et précipitations sur la Corne de l'Afrique	10
2.2.3 Corne de l'Afrique: transition entre deux régions	13
2.3 Hydrologie des sous-bassins majeurs du Nil (SBN)	14
2.3.1 Haut plateau kenyo-ougandais	16
2.3.2 Plaines du Soudan	16
2.3.3 Sobat	17
2.3.4 Haut plateau éthiopien	17

2.4	Variabilité interannuelle des débits du Nil	19
2.5	Modèles de prévision des débits du Nil	23
2.5.1	Modèles statistiques / stochastiques conçus pour la prévision	24
2.5.2	Modèle physique distribué : le système de prévision des débits du Nil (NFS)	27
2.6	Fluctuations des débits et forçage climatique	30
2.6.1	Description de l'ENSO	31
2.6.2	Prévision à partir d'informations climatiques	34
2.6.2.1	Méthodes utilisées	36
2.6.2.2	Résultats des recherches	37
2.7	Discussion générale et méthodes proposées	44
2.7.1	Remarques sur les résultats dégagés de la revue de littérature	44
2.7.2	Remarques sur les méthodes dans la revue de littérature	45
2.7.3	Fonctions de transfert avec bruit	46
2.7.4	Réseaux de neurones artificiels	47

Chapitre III

MÉTHODOLOGIES DE RECHERCHE	50
3.1 Introduction	50
3.2 Fonctions de Transfert avec Bruit (FTB)	51
3.2.1 Présentation et formulation générale	51
3.2.1.1 Composante dynamique	53
3.2.1.2 Terme de bruit	54
3.2.1.3 Formulation générale	55
3.2.2 Hypothèses de base de la modélisation par FTB	55
3.2.3 Identification du modèle	57
3.2.3.1 Méthodes empiriques	57
3.2.3.2 Méthode de Box et Jenkins (1976)	57

3.2.3.3	Méthode de Haugh et Box (1977)	59
3.2.3.4	Méthode de Liu et Hanssens (1982)	59
3.2.4	Estimation des paramètres	60
3.2.5	Validation du modèle	61
3.2.5.1	Vérification de l'autocorrélation des résidus	61
3.2.5.2	Vérification de l'indépendance entre les variables exogènes et le bruit	62
3.2.5.3	Test de normalité	63
3.2.6	Prévision par FTB	64
3.2.7	Erreur de généralisation	67
3.3	Réseaux de neurones artificiels (RNA)	68
3.3.1	Présentation générale et définitions	68
3.3.2	Modèle du neurone	68
3.3.3	Perceptron multicouches	72
3.3.4	Propriétés des réseaux de neurones	75
3.3.4.1	Non-linéarité	76
3.3.4.2	Tolérance au manque d'information	76
3.3.4.3	Résistance aux entrées aberrantes	76
3.3.4.4	Possibilité de se passer de prérequis	77
3.3.4.5	Non-unicité du modèle par rapport aux paramètres	77
3.3.4.6	Adaptabilité	77
3.3.4.7	Utilisation des données à leur état brut	78
3.3.4.8	Autres propriétés	78
3.3.5	Identification d'un RNA	79
3.3.5.1	Choix des entrées du RNA	79
3.3.5.2	Choix du modèle de neurone	79
3.3.5.3	Choix de la structure du modèle	80
3.3.6	Estimation des paramètres (apprentissage) du RNA	81
3.3.7	Limites et précautions dans la modélisation par RNA	83

3.3.7.1	Problème des minima locaux	84
3.3.7.2	Problème de généralisation	84
3.3.8	Validation d'un modèle de RNA	87
3.3.9	Estimation de l'erreur de généralisation	89
3.3.9.1	Validation croisée	89
3.3.9.2	Technique de bootstrap	90
3.3.10	Estimation de l'incertitude associée à la prévision	91

Chapitre IV

DONNÉES DE L'ÉTUDE ET ANALYSES DE CAUSALITÉ.....		94
4.1	Introduction	94
4.2	Débits du Nil	95
4.2.1	Description des données disponibles	95
4.2.2	Débits mensuels d'Assouan	97
4.2.3	Prévisibilité de la crue du Nil	101
4.3	Températures de surface de l'océan (TSO)	104
4.3.1	Description des données	105
4.3.2	Contrôle de la qualité des données	106
4.3.3	Choix des prédicteurs potentiels de la série d'ASSOUAN.....	108
4.3.3.1	Pacifique est.....	109
4.3.3.2	Océan Indien.....	109
4.3.3.3	Atlantique sud.....	111
4.4	Analyse de causalité	113
4.4.1	Modélisation de chacune des séries d'entrée et de sortie	114
4.4.1.1	Modélisation de la série ASSOUAN	114
4.4.1.2	Modélisation de la série WRHOM	116
4.4.1.3	Modélisation de la série STHIND	117
4.4.1.4	Modélisation des séries de l'Atlantique sud :	118

4.4.2	Tests de causalité	121
4.5	Modèles de régression entre le TSO et ASSOUAN.....	124

Chapitre V

MODÉLISATION ET PRÉVISION PAR FONCTIONS DE TRANSFERT AVEC BRUIT ET PAR RÉSEAUX DE NEURONES ARTIFICIELS		126
5.1	Introduction	126
5.2	Modèles de FTB	127
5.2.1	Modèles de FTB avec une seule variable exogène de TSO	128
5.2.2	Modèles de FTB à plusieurs variables exogènes	135
5.2.3	Remarques générales sur les résultats des modèles de FTB	139
5.2.4	Performance des modèles FTB en prévision	140
5.2.5	Test de comparaison entre les prévisions des différents modèles	146
5.3	Modèles de réseaux de neurones artificiels.....	148
5.3.1	Modèles de RNA avec une seule variable exogène de TSO.....	151
5.3.2	Modèles de RNA à plusieurs variables exogènes de TSO.....	157
5.3.3	Performance des modèles de RNA en prévision	167
5.3.4	Test de comparaison entre les prévisions des différents modèles	173
5.4	Comparaison entre les modèles de FTB et de RNA.....	175
5.5	Discussion	182

Chapitre VI

CONCLUSIONS GÉNÉRALES ET PERSPECTIVES DE RECHERCHE	185
--	-----

BIBLIOGRAPHIE	191
---------------------	-----

LISTE DES TABLEAUX

Tableau 2. 1 :	Corrélations entre la PAM du Nil Bleu et différents indices de l'ENSO	40
Tableau 4. 1 :	Stations de jaugeage disponibles sur le Nil et ses tributaires	95
Tableau 4. 2 :	Comparaison entre les modèles ARMA pour la série d'ASSOUAN	116
Tableau 4. 3 :	Statistique Q_L du test de causalité entre d'une part, les séries WRHOM, STHIND et STHATL et d'autre part, la série d'ASSOUAN, avec les valeurs critiques du test au niveau de confiance de 95%	123
Tableau 4. 4 :	Comparaison entre les modèles de régression	125
Tableau 5. 1 :	Comparaison entre les modèles de FTB à une variable exogène	134
Tableau 5. 2 :	Comparaison entre les modèles de FTB à plusieurs variables exogènes.....	138
Tableau 5. 3 :	Performances en prévision des modèles D_{T2} , E_T , F_{T3} , G_T , H_T et J_T ..	146
Tableau 5. 4 :	Résultats de la comparaison par paires de modèles entre les neuf modèles de FTB proposés, utilisant le test de Pitman	148
Tableau 5. 5 :	Comparaison entre les modèles de RNA à une variable exogène	157
Tableau 5. 6 :	Comparaison entre les modèles de RNA à plusieurs variables exogènes.....	167
Tableau 5. 7 :	Performance en prévision des modèles D_N , E_N , F_N , G_N , H_N et J_N	172
Tableau 5. 8 :	Résultats de la comparaison par paires de modèles entre les six modèles de RNA proposés, utilisant le test de Pitman	174
Tableau 5. 9 :	Tableau récapitulatif des indices de performance des modèles de FTB et de RNA.....	175

LISTE DES FIGURES

Figure 2. 1 :	Carte du bassin du Nil.....	7
Figure 2. 2 :	Topographie de la Corne de l'Afrique (d'après Camberlin, 1994).....	9
Figure 2. 3 :	Régimes pluviométriques à différentes régions de la Corne de l'Afrique (d'après Camberlin, 1994)	11
Figure 2. 4 :	Position de la ZCIT (d'après Camberlin, 1994)	12
Figure 2. 5 :	Représentation schématique du Nil.	15
Figure 2. 6 :	Sections longitudinales dans le Nil Blanc et dans le Nil Bleu (d'après Hillel, 1994).....	18
Figure 2. 7 :	L'hydrogramme annuel à Assouan et la contribution moyenne des tributaires majeurs (d'après Hillel, 1994).....	19
Figure 2. 8 :	Variabilité des débits annuels à Assouan de 1870 à 1989.	20
Figure 2. 9 :	Somme des départs cumulatifs de la moyenne de la série chronologique a) d'après Hurst <i>et al.</i> , 1965 b) d'après Evans, 1994..	22
Figure 2. 10 :	Traces de volumes produites par le modèle du couloir (d'après Georgakakos <i>et al.</i> , 1995a)	26
Figure 2. 11 :	Système de prévision du Nil (version 3.0).....	28
Figure 2. 12 :	Exemple de la sortie du modèle ESP (Koren et Barrett, 1994).	29
Figure 2. 13 :	Forçages climatiques agissant sur les précipitations du bassin du Nil (d'après Hulme, 1994).....	31
Figure 2. 14 :	Anomalies chaudes au Pacifique durant la phase El-Niño (d'après NOAA/OGP, 1992).	32
Figure 2. 15 :	Représentation schématique de la circulation de Walker a) année normale b) phase El-Niño.....	33
Figure 2.16 :	Modèle de prévision statistique qui incorpore les informations climatiques	35

Figure 2. 17 :	Différents indices de l'ENSO et leurs discontinuités de printemps (d'après Lin, 1995a).....	40
Figure 2. 18 :	Relations linéaires entre la PAM au Nil Bleu et différents indices de l'ENSO (Lin, 1995b)	41
Figure 2. 19 :	Modèle de FTB pour prédire les pluies en Éthiopie (Seleshi, 1997)..	43
Figure 2. 20 :	Connexions avec les variations interannuelles des précipitations d'été dans la Corne de l'Afrique et la circulation océano-atmosphérique (Camberlin, 1994).....	43
Figure 3. 1 :	Représentation des étapes de construction d'un modèle de Box et Jenkins (d'après Salas <i>et al.</i> , 1980).....	52
Figure 3. 2 :	Représentation d'un modèle de FTB (d'après Hipel et McLeod, 1994).....	55
Figure 3. 3 :	Schéma d'un neurone.....	69
Figure 3. 4 :	Fonctions d'activation de neurone (a) à seuil, (b) linéaires à seuil, (c) sigmoïdes : logistique et tangente hyperbolique	71
Figure 3. 5 :	Réseau de neurones artificiels de type perceptron multicouches avec une seule couche cachée et une sortie.....	73
Figure 3. 6 :	Réseau de neurones artificiels de type NNARMAX avec une seule couche cachée, une sortie et une boucle de moyenne mobile.....	74
Figure 4. 1 :	Hydrogramme annuel aux stations de jaugeage sur le Nil Blanc à (a) Mongalla et à (b) Malakal ; sur le Nil Bleu à (c) Roseiros, à (d) Sennar et à (e) Khartoum et sur (f) l'Atbara	96
Figure 4. 2 :	Moyenne et écart type des débits mensuels d'Assouan.....	97
Figure 4. 3 :	Boxplot des débits mensuels à la station d'Assouan	98
Figure 4.4 :	(a) Pourcentage des volumes saisonniers moyens par rapport au volume annuel moyen à Assouan (b) Pourcentage des volumes	

	moyens des mois de juillet à octobre par rapport au volume moyen d'été à Assouan.....	99
Figure 4. 5 :	Boxplot de la série d'ASSOUAN	100
Figure 4. 6 :	Fluctuations des écoulements du Nil Bleu et du Nil Blanc (a) volumes du printemps à Malakal (Nil Blanc) et (b) volumes d'été à Assouan.....	102
Figure 4. 7 :	Corrélations croisées des débits mensuels à plusieurs délais	103
Figure 4. 8 :	Nombre annuel d'observations de TSO (tirée de Folland et Parker, 1995).	106
Figure 4. 9 :	Vents de surface en été qui atteignent le HPE (d'après Folland <i>et al.</i> , 1991)	108
Figure 4. 10 :	Corrélations entre les débits de juillet et d'août à Roseiros et les TSO aux mêmes mois, calculées sur la période 1948-1972 (tirée de Bhatt, 1989)	110
Figure 4. 11 :	Corrélations entre les précipitations sur le HPE de juillet à septembre et les TSO aux mêmes mois, calculées sur la période 1953-1988 (tirée de Camberlin, 1994).	110
Figure 4. 12 :	Départs standardisés de la moyenne du volume de la crue d'été (ASSOUAN) et des TSO (a) WRHOM et STHIND et (b) STHATL et ATLNAM	112
Figure 4. 13 :	Localisation des régions de TSO utilisées comme prédicteurs potentiels de la crue du Nil.	113
Figure 4. 14 :	(a) Fonction d'autocorrélation (FAC) et (b) fonction d'autocorrélation partielle (FACP) de la série d'ASSOUAN	115
Figure 4. 15 :	(a) Fonction d'autocorrélation (FAC) et (b) fonction d'autocorrélation partielle (FACP) de la série de WRHOM.....	117
Figure 4. 16 :	(a) Fonction d'autocorrélation (FAC) et (b) fonction d'autocorrélation partielle (FACP) de la série de STHIND	118

Figure 4. 17 :	(a) Fonction d'autocorrélation (FAC) et (b) fonction d'autocorrélation partielle (FACP) de la série de ATLNAM.....	119
Figure 4. 18 :	(a) Fonction d'autocorrélation (FAC) et (b) fonction d'autocorrélation partielle (FACP) de la série de STHATL	120
Figure 4. 19 :	Fonction de corrélation croisée (FCC) entre les innovations des séries (a) WRHOM, (b) STHIND, (c) ATLNAM ₁₉₂₀₋₁₉₈₉ et (d) ATLNAM ₁₉₄₅₋₁₉₈₉ et les innovations d'ASSOUAN	122
Figure 4. 20 :	Pourcentage des saisons avec des données disponibles de TSO pour les années (a) 1861-70; (b) 1901-10; (c) 1951-60; (d) 1981-90. Les zones ombrées claires, moyennes et foncées correspondent, respectivement, à des couvertures de 30% à 50%, de 50% à 90% et > 90% (tirée de Parker et al., 1995).....	135
Figure 5. 1 :	Fonction de corrélation croisée (FCC) entre les innovations de la série WRHOM et les résidus des modèles (a) D_{T1} et (b) D_{T2}	130
Figure 5. 2 :	Fonction de corrélation croisée (FCC) entre les innovations de la série STHIND et les résidus du modèle E_T	130
Figure 5. 3 :	Fonction de corrélation croisée (FCC) entre les innovations de la série ATLNAM et les résidus des modèles (a) F_{T1} , (b) F_{T2} et (c) F_{T3}	132
Figure 5. 4 :	Fonction d'autocorrélation (FAC) des résidus des modèles (a) D_{T2} , (b) E_T et (c) F_{T3}	133
Figure 5. 5 :	Fonction de corrélation croisée (FCC) entre d'une part, les innovations des séries (a) WRHOM et (b) STHIND et d'autre part, les résidus du modèle G_T	136
Figure 5. 6 :	Fonction de corrélation croisée (FCC) entre d'une part, les innovations des séries (a) WRHOM et (b) STHIND et d'autre part, les résidus du modèle J_T	137
Figure 5. 7:	Fonction d'autocorrélation (FAC) des résidus du modèle J_T	137

Figure 5. 8 :	Volumes de la crue d'été à Assouan ajustés en utilisant les modèles de FTB : (a) D_{T2} , (b) E_T , (c) F_{T3} , (d) G_T , et (e) J_T	142
Figure 5. 9 :	Volumes de la crue d'été à Assouan prédits en utilisant les modèles de FTB : (a) D_{T2} , (b) E_T , (c) F_{T3} , (d) G_T , et (e) J_T	144
Figure 5. 10 :	Fonctions de corrélation croisée pour valider le modèle D_N (X étant WRHOM, et $\alpha_i(t) = Y(t) \cdot e(t)$)	153
Figure 5. 11 :	Fonctions de corrélation croisée pour valider le modèle E_N (X étant STHIND, et $\alpha_i(t) = Y(t) \cdot e(t)$)	154
Figure 5. 12 :	Fonctions de corrélation croisée pour valider le modèle F_N (X étant ATLNAM, et $\alpha_i(t) = Y(t) \cdot e(t)$)	155
Figure 5. 13 :	Fonction d'autocorrélation des résidus des modèles (a) D_N , (b) E_N et (c) F_N	156
Figure 5. 14 :	Fonctions de corrélation croisée pour valider le modèle G_N : (a) X étant WRHOM, (b) X étant STHIND et $\alpha_i(t) = Y(t) \cdot e(t)$	159
Figure 5. 15 :	Fonctions de corrélation croisée pour valider le modèle H_N (a) X étant WRHOM, (b) X étant ATLNAM et $\alpha_i(t) = Y(t) \cdot e(t)$	161
Figure 5. 16 :	Fonctions de corrélation croisée pour valider le modèle I_N (a) X étant WRHOM, (b) X étant STHIND, (c) X étant ATLNAM et $\alpha_i(t) = Y(t) \cdot e(t)$	163
Figure 5. 17 :	Fonction d'autocorrélation des résidus des modèles (a) G_N , (b) H_N et (c) I_N	166
Figure 5. 18 :	Volumes de la crue d'été ajustés utilisant les modèles de RNA : (a) D_N (b) E_N (c) F_N (d) G_N (e) H_N et (f) I_N	168
Figure 5. 19 :	Volumes de la crue d'été prédits, utilisant les RNA, pour les modèles : (a) D_N (b) E_N (c) F_N (d) G_N (e) H_N et (f) I_N	170
Figure 5. 20 :	Comparaison entre les prévisions utilisant les modèles de FTB et de RNA pour le modèle de type (a) D , (b) E , (c) F , (d) G , (e) H et (f) I 176	

LISTE DES SIGLES ET ABRÉVIATIONS

<i>A</i>	Modèle de bruit blanc
AM	Climatologie globale d'Alexander et Mobley
AR	Autoregressive
ARIMA	Autoregressive Integrated Moving Average
ARMA	Autoregressive Moving Average
ARMAX	Autoregressive Moving Average with eXogenous Variable
ASSOUAN	Volume cumulatif des apports naturels qui entrent à la station de jaugeage en amont du Haut Barrage d'Assouan durant les mois de juillet à octobre
ATLEQU	Moyenne des anomalies de TSO sur une bande de 10° au sud de l'équateur météorologique
ATLNAM	Moyenne des anomalies de TSO sur une région près de la côte namibienne au sud de l'Atlantique (de 15°N à 35°N et de 10°O à 10°E)
AVHRR	Advanced Very High Resolution Radiometer
<i>B</i>	Modèle AR(3) pour la série d'ASSOUAN
B_i	Nombre des échantillons de bootstrap
B^k	Opérateur de translation – arrière au délai k
$bmin_i$	Décalage requis avant que la série d'entrée X_{it} n'affecte Y_t .
<i>C</i>	Modèle MA(3) pour la série d'ASSOUAN
CDS	Consolidated Data Set
C_i	Ensemble des échantillons de bootstrap
c_i	Cas à prédire
CIA	Critère d'information d'Akaike
CIB	Coefficient d'information bayésien
CMPARMA	Contemporaneous Multivariate Periodic Autoregressive Moving Average
c_n, k_n, r_n	Paramètre de la fonction sigmoïde
COADS	Comprehensive Ocean Atmospheric Data Set
CR	Coefficient de ruissellement

c_{uu}	Coefficient de covariance au délai k
c_{uv}	Coefficient de covariance croisée au délai k
CVH	Confluence de vent hémisphérique
D_i	Différence absolue entre les carrés des résidus de deux modèles dans le test de Wilcoxon
D_N	Modèle de RNA de type D
D_R	Modèle de régression de type D
D_t	Différence entre les résidus de deux modèles dans le test de Pitman
D_{T1}, D_{T2}	Modèles de FTB de type D
EM	Équateur météorologique
E_N	Modèle de RNA de type E
ENSO	El-Niño / Southern Oscillation
EPF	Erreur de prévision finale
E_R	Modèle de régression de type E
$err_{0.632}$	Erreur estimée par la technique de bootstrap 0.632
err_{app}	Erreur apparente de prévision (dans l'estimation par bootstrap)
ESP	Extended Streamflow Prediction
E_T	Modèle de FTB de type E
e_t	Résidus d'un modèle
FAC	Fonction d'autocorrélation
FACP	Fonction d'autocorrélation partielle
FARMA	Fractional Autoregressive Moving Average
FCC	Fonction de corrélation croisée
FGN	Fractional Gaussian Noise
f_h	Fonction d'activation du neurone de la couche cachée
f_j	Fonction d'activation du neurone j
F_N	Modèle de RNA de type F
f_o	Fonction d'activation du neurone de la sortie
F_{OBJ}	Fonction objectif

F_R	Modèle de régression de type F
F_{T1}, F_{T2}, F_{T3}	Modèles de FTB de type F
FTB	Fonction de transfert avec bruit
GCM	Global Circulation Model
GISS2.2	Global Sea Ice and Sea Surface Temperature data set version 2.2
G_N	Modèle de RNA de type G
GOSTAplus	Global Ocean Surface Temperature Atlas Plus
G_R	Modèle de régression de type G
G_T	Modèle de FTB de type G
H	Matrice hessienne
HBA	Haut barrage d'Assouan
H_N	Modèle de RNA de type H
HPE	Haut plateau éthiopien
HPKO	Haut plateau kenyo-ougandais
H_R	Modèle de régression de type H
H_T	Modèle de FTB de type H
HU	Nombre de neurones sur la couche cachée
I	Matrice identité
IID	Indépendants et identiquement distribués
I_N	Modèle de RNA de type I
I_{n_j}	Entrée de la fonction d'activation du neurone j
I_R	Modèle de régression de type I
I_T	Modèle de FTB de type I
it	Itération
J	Matrice jacobienne
J_T	Modèle de FTB de type J
JTE	Jet tropical de l'est
K	Exponentiel de Hurst
k	Délai

L	Plus grand délai considéré dans les tests de Portemanteau ou de causalité
l	Horizon de prévision
LCI	Limite inférieure de confiance de la sortie du modèle
LCS	Limite supérieure de confiance de la sortie du modèle
LPI	Limite inférieure de confiance de la prévision
LPS	Limite supérieure de confiance de la prévision
M	Moyenne
m	Nombre de séries d'entrée incorporées dans un modèle
MA	Moving Average
MDA	Moyenne des différences absolues
MIT	Massachusetts Institute of Technology
MOMMDB	Meteorological Office Main Marine Data Base
m_p	Nombre total de paramètres (de poids et seuils) utilisé par le modèle
$MPEA$	Moyenne des pourcentages des erreurs absolues
MTPRH	Ministère des travaux publics et des ressources hydriques d'Égypte
n	Nombre d'observations
n_f	Nombre des valeurs prédites.
NFS	Nile Forecasting System
NID	Normaux et identiquement distribués
n_j	Neurone j
$NNARMA$	Neural Networks Autoregressive Moving Average
$NNARMAX$	Neural Networks Autoregressive Moving Average with eXogenous Variable
$NNARX$	Neural Networks Autoregressive with eXogenous Variable
NOAA	National Oceanic and Atmospheric Administration
N_t	Terme du bruit dans la fonction de transfert avec bruit
NWS	National Weather Service
Out_j	Sortie de la fonction d'activation du neurone j
p	Ordre de l'opérateur de moyenne mobile

PAM	Précipitation sur l'aire moyenne
PAR	Periodic autoregressive
PNM	Pression au niveau de la mer
q	Ordre de l'opérateur autorégressif
Q_L	Statistique des tests de Portemanteau ou de causalité
R	Capacité du réservoir dans l'équation de Hurst
r	Coefficient de corrélation
R^2	Coefficient de détermination
REQM	Racine carrée de l'erreur quadratique moyenne
r_i	Ordre des opérateurs du dénominateur de la fonction impulsion-réponse associée à la série d'entrée X_{it}
RNA	Réseaux de neurones artificiels
r_{uu}	Coefficient d'autocorrélation au délai k
r_{uv}	Coefficient de corrélation croisée au délai k
s_i	Ordre de l'opérateur du numérateur de la fonction impulsion-réponse associée à la série d'entrée X_{it}
S_j	Seuil de la fonction d'activation du $j^{\text{ième}}$ neurone sur la couche cachée
S_o	Seuil de la fonction d'activation du neurone de sortie
SOI	Southern Oscillation Index
S_t	Somme des résidus de deux modèles dans le test de Pitman
STHATL	Moyenne des anomalies de TSO sur tout l'Atlantique au sud de l'équateur météorologique
STHIND	Moyenne des anomalies de TSO sur une région de 20°S à 40°S et 50°E à 80°E) (dans l'océan indien sud)
TCMPARMA	Truncated Contemporaneous Multivariate Periodic Autoregressive Moving Average
TSO	Température de surface de l'océan
u_{it}	Série d'innovation (résidus du meilleur modèle ARIMA) pour une série d'entrée X_{it}

UKMO	United Kingdom Meteorological Office
UNESCO	United Nations Educational, Scientific and Cultural Organization
$Var(l)$	Variance de la prévision à un horizon l
$V_i(B)$	Opérateur de la fonction impulsion-réponse de la $i^{ième}$ entrée
v_{ji}	Paramètre de la fonction impulsion-réponse au délai j de l'entrée i
WH_{ij}	Poids de la connexion entre la $i^{ième}$ entrée et le $j^{ième}$ neurone sur la couche cachée
W_{ij}	Poids de la connexion entre la $i^{ième}$ élément et le $j^{ième}$ élément dans un réseau de neurone
WO_j	Poids de la connexion entre le $j^{ième}$ neurone sur la couche cachée et le neurone de sortie
WRHOM	Indice de l'ENSO constitué en faisant la moyenne des TSO sur une région qui s'étend de 6°N à 12°N, et 179°O à 90°O ; de 2°N à 6°S et 180°O à 90°O ; de 6°S à 10°S et 150°O à 110°O (au Pacifique est)
Xb	Échantillons de bootstrap
X_{it}	Série d'entrée
$\hat{Y}_c \eta_{Xb}$	Erreur de prévision du modèle pour le cas c_i , calculée à partir de tous les modèles avec des paramètres η_{Xb} , ajustés sur certains échantillons de bootstrap Xb
Y_t	Série de sortie
$\hat{Y}_t$	Prévisions à un pas de temps
ZCIT	Zone de convergence intertropicale
α_p	Coefficient de régularisation
α_r	Produit de la sortie du modèle par les résidus
β_t	Série de sortie filtrée
$\Delta_i(B)$	Opérateur du dénominateur de la fonction impulsion-réponse associée à la $i^{ième}$ entrée
δ_{ij}	Paramètre du dénominateur au délai j de l'entrée i

ε_o	Moyenne des erreurs obtenues par des RNA entraînés avec des échantillons de bootstrap qui ne contiennent pas le cas prédit
$\mathcal{O}(B)$	Opérateur de moyenne mobile
θ_j	Paramètre de moyenne mobile au délai j
θ_{RNA}	Paramètre du réseau de neurones
$\hat{\theta}_{RNA}$	Paramètre du réseau de neurones qui minimise la fonction objectif
σ	Écart type
σ^2	Variance
$\Phi(B)$	Opérateur autorégressif
ϕ_j	Paramètre autorégressif au délai j
$\Omega_i(B)$	Opérateur du numérateur de la fonction impulsion-réponse associée à la $i^{\text{ème}}$ entrée
ω_{ji}	Paramètre du numérateur au délai j de l'entrée i

Chapitre I

INTRODUCTION

La civilisation humaine a débuté à proximité des grands fleuves. La fertilité des terres, la disponibilité de l'eau ainsi que l'organisation de la société primitive afin de gérer les cours d'eau ont été à la source des grandes civilisations. La prévision des épisodes de sécheresse et d'inondation a toujours été une composante importante de cette gestion. Dans les textes de la mythologie ancienne et des livres sacrés, on a fait aussi référence à cette prévision. Actuellement, la prévision des apports naturels reste une question importante pour de nombreux pays.

L'Égypte, en particulier, dépend, pour plus de 90% de ces ressources en eau, sur la crue du Nil qui remplit le lac Nasser en amont du Haut Barrage d'Assouan (HBA). L'Égypte fait partie actuellement des pays en déficit en eau avec seulement 922 m³/an per capita, alors que le seuil de déficit établi par l'Organisation des Nations Unies pour l'alimentation et l'agriculture est de 1000 m³/an per capita (*Food and Agriculture Organization*, 1993). Vu la croissance démographique qui n'est pas accompagnée par une croissance analogue des ressources hydriques, la quantité d'eau per capita chutera à 337 m³/an en 2025 (Abu-Zeid et Hefny, 1992). C'est pourquoi toute réduction de l'incertitude associée à la disponibilité de la crue du Nil est un besoin crucial et la construction importante du HBA en est un témoin permanent.

C'est ainsi que plusieurs modèles pour la prévision des débits du Nil ont été construits au cours des dernières décennies. Ces modèles peuvent être divisés en trois types selon les variables d'entrée qui sont : les débits antérieurs, les précipitations ou l'information climatique. La crue du Nil est caractérisée par une forte variation interannuelle, qui rend impossible la prévision de la crue à partir uniquement des débits des années antérieures. De plus, l'utilisation des précipitations comme variable d'entrée

ne permet pas d'étendre l'horizon de prévision au-delà d'un mois, qui correspond au temps de réponse hydrologique des tributaires du Nil qui transportent la crue. De plus, cet horizon de prévision est insuffisant pour permettre une gestion efficace du Haut Barrage d'Assouan pendant la période estivale caractérisée par des consommations importantes en eau.

Nos travaux de recherche ont pour objectif la construction de modèles de prévisions à moyen terme, soit trois mois à l'avance. Ces modèles devraient être capables de prédire les volumes cumulatifs de la crue du Nil qui commence au mois de juillet, a sa pointe en septembre et se termine en octobre, avec un mois de décalage sur les précipitations. Les modèles de prévision que nous proposons sont de type stochastique et statistique. Ils utilisent, comme variables exogènes, des indices de la variabilité climatique, permettant ainsi d'étendre l'horizon de prévision. La complexité des modèles qui incorporent les indices climatiques est double, car il s'agit d'abord de trouver les indices qui peuvent fournir des prévisions fiables et ensuite de choisir un modèle de prévision reproduisant la structure dynamique de la relation temporelle entre les variables exogènes climatiques et la sortie hydrométrique. Au niveau actuel de la connaissance scientifique en climatologie, il est difficile de modéliser cette relation par un modèle de circulation globale qui simule les équations différentielles qui gèrent le système océano-atmosphérique.

Vu la compréhension limitée des processus qui gèrent la relation entre les températures de surface de l'océan (TSO) et les débits, notre démarche est de type exploratoire. Elle consiste tout d'abord à explorer les indices climatiques connus, comme ceux qui caractérisent le système océano-atmosphérique qui groupe le courant maritime d'El-Niño avec l'Oscillation Australe de la pression atmosphérique au Pacifique (*El-Niño / Southern Oscillation*, ENSO). Cependant, les modèles qui ne comportent qu'un indice de l'ENSO ne sont pas assez performants pour être utilisés en prévision opérationnelle. Alors, nous avons identifié les TSO d'autres régions de

l'océan global qui pourraient être téléconnectées à la crue du Nil. Ces nouveaux indices climatiques seront incorporés avec l'indice de l'ENSO dans notre modèle. Cette exploration est rendue possible grâce aux recherches récentes en climatologie.

Une fois les séries temporelles des prédicteurs potentiels élaborées, une analyse de causalité statistique est entreprise pour retenir les variables qui "causent" la crue du Nil. Avec les variables retenues, plusieurs modèles de prévision sont construits allant des modèles de régression simple et multiple, jusqu'aux modèles plus structurés, tels que fonctions de transfert avec bruit (FTB) et les réseaux de neurones artificiels (RNA). Pour chacune des techniques, des modèles à une seule puis à plusieurs variables exogènes sont construits. De plus, pour les modèles de FTB et de RNA les composantes de délai de la série de sortie sont identifiées et introduites dans le modèle.

Pour que le modèle soit d'utilité opérationnelle pour les gestionnaires des ressources hydriques, il faudrait que les indices climatiques soient facilement accessibles et que la prévision soit précise. Cela ajoute donc deux contraintes supplémentaires au modèle. D'une part, les mesures de performance du modèle doivent être élevées : un coefficient de corrélation inférieur à 0,8 est insuffisant pour une gestion fiable. D'autre part, les indices climatiques doivent être faciles à extraire des données brutes. De même, les limites du modèle doivent être identifiées et une estimation de l'incertitude associée à la prévision se doit d'être réalisée.

Cette thèse est organisée en six chapitres. Suite à cette introduction, le chapitre II présente une revue de littérature synthétique des travaux nombreux qui ont traité de la prévision des débits du Nil, leurs avantages et leurs lacunes. Le but de ce chapitre est de permettre au lecteur de mieux comprendre les enjeux d'un modèle de prévision des apports naturels du Nil. C'est pourquoi il commence par une description des champs atmosphériques et des régimes pluviométriques qui dominent les sources du Nil.

Ensuite, une description du réseau hydrographique du Nil est présentée ainsi que les téléconnexions entre, d'une part les précipitations et les débits du Nil, et d'autre part les indices climatiques. La revue de littérature se termine par une critique des méthodes utilisées, suivie d'une justification de l'emploi des fonctions de transfert avec bruit (FTB) et des réseaux de neurones artificiels (RNA) pour la prévision des débits du Nil.

La présentation des modèles de FTB et de RNA, utilisés dans cette thèse, se trouve au chapitre III. Elle couvre la formulation générale des modèles, les hypothèses de base sous-jacentes, la détermination de la structure des modèles, l'estimation de leurs paramètres, la validation des modèles et l'utilisation des modèles en prévision. La présentation des modèles de RNA est particulièrement détaillée, avec l'utilisation des corrélations croisées d'ordre élevé pour la validation des modèles et d'une technique de bootstrap pour la construction des intervalles de confiance pour la prévision. Ces techniques de validation et de bootstrap sont appliquées pour la première fois en hydrologie.

Le chapitre IV décrit les données utilisées dans cette recherche. Celles-ci proviennent de deux sources : la sortie du modèle qui est les débits à une station hydrométrique située en amont du Haut Barrage d'Assouan et les variables exogènes qui sont les températures de surface de l'océan (TSO) à différentes régions du globe. Nous démontrons comment les débits antérieurs ne sont pas suffisants pour prédire, trois mois à l'avance, le volume cumulatif des débits des mois de la crue. Le choix des indices climatiques à incorporer comme prédicteurs potentiels dans notre modèle de prévision est justifié. La causalité entre ces variables exogènes et la sortie est ensuite établie. Ce chapitre IV se termine par une application des modèles de régression simple et multiple pour prédire le volume de la crue du Nil. Les résultats de cette application sont limités et suggèrent l'utilisation de modèles plus complexes.

L'application des FTB, suivie de celle des RNA fait l'objet du chapitre V. Pour chaque type, les modèles avec une seule variable exogène de TSO sont d'abord présentés, suivis par les modèles à plusieurs variables. Les résultats des modèles de FTB et de RNA sont présentés et commentés. Les modèles sont validés à partir de plusieurs indices sur des échantillons qui n'ont pas servi pour l'estimation des paramètres. Une comparaison des techniques de FTB et de RNA permet de tirer des conclusions intéressantes applicables à différentes problématiques de prévision des débits utilisant les indices climatiques. Le chapitre V se termine par une interprétation climatologique originale des résultats de nos modèles de prévision.

Enfin, la conclusion générale au chapitre VI dégage les principales innovations apportées par nos modèles de prévision et propose des perspectives de recherche intéressantes suite à notre travail.

Chapitre II

DESCRIPTION, MODÉLISATION ET PRÉVISION HYDROLOGIQUES DU NIL

2.1 Introduction

Le Nil compte parmi les fleuves les plus longs au monde. Il draine 3,1 millions de km² sur son cours de 6 671 km (soit 10% de l'Afrique), traversant dix pays africains (Burundi, Rwanda, Tanzanie, Congo, Kenya, Ouganda, Éthiopie, Érythrée, Soudan, Égypte). Il couvre presque tout le territoire de la Corne africaine et fournit, à lui seul, l'eau douce à plus de 90 millions de personnes en Égypte et au nord du Soudan. Le Nil traverse quatre zones climatiques : équatoriale, tropicale, semi-aride et désertique ou aride ; tandis que ses sources sont entièrement comprises dans les zones équatoriale et tropicale de la Corne africaine. Comme le montre la figure 2.1, le Nil a quatre grands tributaires : le Nil blanc, le Sobat, le Nil Bleu et l'Atbara. Il trouve ses origines dans deux plateaux : le Nil Blanc dans le haut plateau kenyo-ougandais (HPKO) et le Nil Bleu et l'Atbara dans le haut plateau éthiopien (HPE). Le bassin du Nil comprend cinq grands lacs naturels : Victoria, Edouard, Albert (ou Mobutu Sesse-Seko), Kyoga et Tana ; de vastes espaces marécageux permanents ou saisonniers (le Sudd, Bahr-el-Ghazal et Bahr-el-Arab, et les marais de Machar) ; cinq barrages à réservoirs (Haut barrage d'Assouan (HBA) sur le Nil principal, Roseiros et Sennar (sur le Nil Bleu), Khashm-el-Girba (sur l'Atbara) et Jebel-el-Aulia (sur le Nil Blanc)) ; et cinq centrales hydroélectriques (HBA, l'ancien barrage d'Assouan, Tis Isat, Finchaa et les chutes d'Owen) (Whittington et Guariso, 1983; Shahin, 1985; Howell et Allan, 1994).

L'importance du Nil, surtout pour l'Égypte, a suscité des centaines de recherches couvrant des domaines allant de l'hydrologie à l'hydraulique, de l'environnement à la microbiologie, de l'anthropologie à la politique, sans oublier tous les aspects socio-économiques. Ce chapitre se limite au domaine de l'hydrologie et plus spécifiquement




Figure 2. 1 : Carte du bassin du Nil.

aux modèles de prévision et de simulation des débits du Nil. La section 2.2 traite de la géographie de la Corne africaine et des champs atmosphériques générant les précipitations sur les sources du Nil. La section 2.3 est consacrée à la description hydrologique des sous-bassins majeurs du Nil et la section 2.4 aux fluctuations des débits annuels qui ont donné lieu au phénomène de Hurst. Les modèles de prévision statistiques / stochastiques et déterministes sont présentés à la section 2.5. Les forçages climatiques à la source des fluctuations interannuelles des débits du Nil sont décrits à la section 2.6. Finalement, une critique des études présentées est élaborée à la section 2.7, suivie d'une présentation des modèles de prévision proposés dans cette thèse.

2.2 Corne de l'Afrique : description

2.2.1 Description générale

La Corne orientale de l'Afrique s'étend entre les latitudes 5°S et 20°N. Une opposition est-ouest existe entre une bordure océanique (l'océan Indien) à l'est et une masse continentale (l'Afrique) à l'ouest. L'océan Indien, qui borde aussi bien le côté sud-est de la Corne, constitue un espace maritime continu sur plusieurs milliers de kilomètres. À l'ouest et au sud-ouest de l'Afrique, à plus de 2 500 km de la Corne, l'Atlantique sud joue un rôle important par rapport à la pluviométrie au Sahel et jusqu'en Afrique de l'est. À l'ouest de la Corne, le reste de l'Afrique forme une masse compacte et continue avec un relief peu marqué qui ne présente pas d'obstacles aux flux atmosphériques.

Quant à la Corne elle-même, on observe une bande méridienne de reliefs élevés, séparant la côte à l'est et la vallée du Nil à l'ouest (figure 2.2). Cette barrière montagneuse est constituée des hauts plateaux éthiopien et kenyo-ougandais, séparés du sud au nord par un couloir au niveau du lac Turkana et de l'ouest à l'est par la fracture du Rift Valley. En Afrique de l'est, la topographie est un déclencheur majeur de la

précipitation à travers l'advection orographique, la canalisation des vents par les reliefs massifs ou plus généralement par la convection initiée par le réchauffement du plateau (Camberlin, 1997).




Figure 2. 2 : Topographie de la Corne de l'Afrique (d'après Camberlin, 1994)

2.2.2 Champs atmosphériques et précipitations sur la Corne de l'Afrique

Suivant Nicholson et Entekhabi (1986), il est préférable de diviser l'année en quatre saisons de durées inégales :

- une saison d'hiver boréal : de décembre à mars;
- une saison d'été boréal : de juin à septembre; et
- deux courtes saisons de transition : celle du printemps boréal (avril - mai) et celle de l'automne boréal (octobre - novembre).

Aux sources du Nil Bleu, 80% des précipitations ont lieu en été, mais aux sources du Nil Blanc, le régime est bimodal ou parfois trimodal (pics "équatoriaux" du printemps et de l'automne et pic d'été, Davies *et al.*, 1985 cités dans Camberlin, 1994) (figure 2.3).

L'aspect fondamental des mécanismes gouvernants ce cycle saisonnier est le déplacement de la Zone de Convergence Intertropicale (ZCIT). Ce terme très large correspond aux basses pressions situées au niveau de l'Équateur Météorologique (EM) entre les deux cellules anticycloniques subtropicales, aussi bien qu'à l'axe de confluence et la bande de convergence qui sont associés aux basses pressions (Hastenrath, 1991). La position de la ZCIT en latitude varie selon le mouvement apparent du soleil (figure 2.4, compilée par Camberlin, 1994). Dans la zone intertropicale, la circulation atmosphérique peut être séparée en une composante méridienne (nord - sud), dite de Hadley, et une composante zonale (est-ouest), dite de Walker. La circulation de Hadley est responsable en grande partie du mouvement de la ZCIT ; tandis que la circulation de Walker influence significativement la variabilité (interannuelle surtout) de la pluviométrie (Janicot et Fontaine, 1993). L'exposé qui suit décrit le mouvement de la ZCIT pendant les mois d'avril à octobre.




Figure 2.3 : Régimes pluviométriques à différentes régions de la Corne de l'Afrique
(d'après Camberlin, 1994)

- La ZCIT remonte vers le nord pendant les mois d'avril et de mai. Un faible flux sud-est domine, emportant de l'humidité de l'océan Indien et donnant naissance à la première saison de pluies au Kenya et en Somalie (Davies *et al.*, 1985). La mousson humide du sud-ouest fait son apparition ; mais elle est peu épaisse et incapable de gagner le sommet du haut plateau éthiopien.




Figure 2. 4 : Position de la ZCIT (d'après Camberlin, 1994)

- La ZCIT, à partir du mois de juin à septembre, est alors à sa position la plus septentrionale et les flux de sud-ouest dominant sur la Corne (Camberlin, 1994) :
 - * le flux de la “mousson indienne” prend une direction sud-ouest dans les massifs du Kenya et du sud-est de l’Éthiopie, une branche s’engouffrant dans le couloir du lac Turkana.
 - * le flux de la “mousson atlantique” ou “congolaise” s’impose sur la façade occidentale et jusqu’au nord-ouest de l’Éthiopie. Même si l’origine lointaine de ce flux est l’Atlantique sud, l’humidité advectée provient en fait du bassin du Congo.
- La limite entre les deux moussons, appelée la “confluence de vent hémisphérique” (CVH), est difficile à trancher. À l’échelle moyenne, la CVH peut être placée à l’ouest du bassin du Nil Blanc ; ce qui, en général, attribuerait les pluies d’été sur le plateau Kenyo-Ougandais à la mousson indienne (Okoola, 1990, cité dans Camberlin, 1994). Cela n’exclut pas tout à fait que la CVH pourrait se situer beaucoup plus à l’est dans quelques années.

- En octobre, la ZCIT redescend rapidement et donne lieu à la seconde saison de pluies aux sources du Nil Blanc et à la sécheresse aux sources du Nil Bleu.
- Il est à noter que l'hiver constitue une période sans précipitation importante sur tout le bassin du Nil.

À la lumière de l'analyse précédente des champs atmosphériques et des régimes de flux, trois saisons de pluies sont plus ou moins importantes sur le bassin du Nil : l'été (juin - septembre) sur tout le bassin mais surtout sur le HPE (source du Nil Bleu), le printemps (avril - mai) et l'automne (octobre - novembre) sur le HPKO (source du Nil Bleu). La transformation de ces précipitations en écoulement fluvial dépend des caractéristiques hydrologiques des sous-bassins et des caractéristiques hydrauliques du cours d'eau. Cela fera l'objet de la section 2.3.

2.2.3 Corne de l'Afrique: transition entre deux régions

Comme nous l'avons vu, la Corne de l'Afrique est affectée aussi bien par la mousson africaine qu'indienne. Bien que le nord de la Corne ait été considéré dans quelques études comme étant une partie intégrante du Sahel (p. ex. Palmer, 1986), la définition de Nicholson (1985) du Sahel avec la vallée du Nil comme limite orientale est la plus proche de la réalité. Cette confusion provient de la ressemblance au niveau des variations interannuelles des pluies et de la tendance à la baisse qu'ont connue les deux régions. Les précipitations de l'Éthiopie du nord sont corrélées ($r=0,65$, significatif au seuil de 1%) avec l'indice sahélien des précipitations de Nicholson (Nicholson et Entekhabi, 1986) pour la période de 1953 à 1984. Flohn (1987) a trouvé également des fortes corrélations entre les débits de l'Atbara et du Nil Bleu et le même indice.

La relation entre les précipitations sur la Corne de l'Afrique et la mousson indienne a fait l'objet d'études depuis Walker et Bliss (1932) et Bliss (1932). Bhatt

(1989) indique une corrélation de 0,84 et 0,69 entre d'un côté, un indice des précipitations indiennes (*All India Summer Monsoon*, Parthasarathy *et al.*, 1991) et de l'autre, les débits en amont du barrage de Roseiros (Nil Bleu) et la station de jaugeage de l'Atbara, et ceci respectivement. Les résultats de Camberlin (1997) montrent une corrélation, assez stable dans le temps, avec les précipitations sur l'ensemble de l'ouest de la Corne et la pression de Bombay (Inde). Dans cette relation, les phases du système océano-atmosphérique qui groupe le courant maritime d'El-Niño avec l'Oscillation Australe de la pression atmosphérique au Pacifique (*El-Niño / Southern Oscillation*, ENSO) semblent avoir une influence importante. Cependant, l'influence de l'ENSO sur cette relation est non déterminante, car la corrélation partielle entre les précipitations sur le HPE et la pression indienne, indépendamment de l'indice de l'ENSO, reste significative (Camberlin, 1993).

2.3 Hydrologie des sous-bassins majeurs du Nil (SBN)

Huit sous-bassins majeurs peuvent être identifiés à l'intérieur du bassin du Nil (cf. figure 2.1). Ils sont divisés selon le système de drainage, les caractéristiques topographiques des sous-bassins, leurs régimes pluviométriques ainsi que la disponibilité des sites de jaugeage. Les huit sous-bassins du Nil sont : le lac Victoria, les lacs équatoriaux (Albert, Édouard, Kyoga, Kivu), le Sudd, le Bahr-el-Ghazal, le Sobat, le Soudan central, le Nil Bleu, et l'Atbara. Une revue plus détaillée de ces sous-bassins est dans Hurst (1957), Shahin (1985) et Sutcliffe et Lazenby (1994). La figure 2.5 est une représentation schématique du Nil avec l'emplacement des stations clés de jaugeage. Vu que le but de cette recherche est la prévision du volume d'eau qui parvient au réservoir du HBA, un élément essentiel de la description qui suit est la contribution à Assouan de chaque sous-bassin. On pourrait grouper ces huit sous-bassins en quatre sous-bassins plus grands : le plateau kenyo-ougandais, les plaines du Soudan, le Sobat et le plateau éthiopien.




Figure 2. 5 : Représentation schématique du Nil.

2.3.1 Haut plateau kenyo-ougandais

Le Nil blanc draine tout le plateau kenyo-ougandais. Celui-ci est à plus de 1 000 m d'altitude et se compose d'un système de lacs (Victoria, Kyoga, Albert, Édouard et Kivu). Le lac Victoria occupe une grande portion (67 000 km²) du total du sous-bassin (258 000 km²). Il a fait l'objet de nombreuses études (entre autres Lyons, 1906; Hurst, 1957; Kite, 1981; Hydromet, 1984; Piper *et al.*, 1986; Yin et Nicholson, 1998). L'Organisation des Nations Unies pour l'éducation, la science et la culture (*United Nations Educational, Scientific and Cultural Organization*, UNESCO) a publié une bibliographie extensive des études les plus importantes sur le Lac Victoria (Crul *et al.*, 1995).

À la sortie du lac Victoria (au barrage des chutes d'Owen, station de Jinja) le fleuve se dirige vers le lac Kyoga, puis vers les lacs Albert et Édouard, et jusqu'à la station de Mongalla. Dû à l'absence de mesures fiables de l'évaporation des lacs équatoriaux et des apports des différentes rivières torrentielles qui s'y jettent, la contribution des lacs équatoriaux est calculée selon la différence entre le débit mesuré à Jinja et celui mesuré à Mongalla. Cette dernière station donne le débit provenant du plateau kenyo-ougandais. La contribution de ce tronçon au volume annuel du Nil principal à Assouan est de moins de 20%.

2.3.2 Plaines du Soudan

Après Mongalla, le Nil Blanc, appelé dans ce tronçon Bahr-el-Jebel, traverse une plaine marécageuse – le Sudd –, puis rencontre les deux tributaires : Bahr-el-Ghazal et Bahr-el-Arab. Malgré la grandeur de ces plaines et la présence de deux tributaires, le bilan final est négatif : le Nil Blanc connaît une perte considérable d'eau par évaporation. Le Sudd, spécialement, a fait l'objet d'études extensives dans le cadre du projet de

construction du canal de Jonglei et des craintes ont été soulevées sur l'impact environnemental de ce projet (Jonglei Investigation Team, 1946 - 1954).

2.3.3 Sobat

Le Sobat comprend deux tributaires majeurs : Baro, le plus large, qui a sa source dans le plateau éthiopien ; et Pibor qui émerge du nord de l'Ouganda. L'apport du Baro est très saisonnier, tandis que celui du Pibor l'est moins. Leur combinaison est moins saisonnière que les tributaires plus au nord, mais avec un pic d'été très marqué. Son hydrogramme, unique parmi les différents tributaires du Nil, fait la spécificité du Sobat et rend difficile de le classer avec l'un ou l'autre des tributaires des deux plateaux. Divers tributaires du Sobat tendent à former des étangs permanents ou saisonniers. Hurst (1957) a estimé les pertes du Baro à 30% et celles du Pibor à 14%. Le Sobat contribue 12% du débit d'Assouan.

2.3.4 Haut plateau éthiopien

En plus du Baro, tributaire du Sobat, le plateau éthiopien est drainé par deux grandes rivières : le Nil Bleu et l'Atbara. Ce plateau est la source de plus de 80% de la crue du Nil. Bien que le bassin du Nil Blanc soit plus large, les pertes d'eau dans les marécages diminuent son apport final (incluant le Sobat) au volume qui arrive à Assouan (35% du volume annuel).

Le Nil Bleu est le tributaire le plus important pour l'Égypte (53% du volume annuel). Il émerge du lac Tana en Éthiopie à 1 843 m d'altitude. Cependant, 7% uniquement de son débit proviennent de ce lac. Ensuite, le Nil Bleu descend une pente très raide sur les montagnes éthiopiennes (figure 2.6). Cette pente raide fait que le bassin du Nil Bleu a le plus grand coefficient de ruissellement dans le bassin du Nil ($CR=0.21$).

Le haut bassin du Nil Bleu débouche à El-Diem en amont du réservoir Roseries (Soudan). Le Nil bleu traverse le territoire soudanais recevant à l'aval de Sennar l'apport de ces deux derniers tributaires : le Rahad et le Dinder, qui trouvent leurs sources dans le plateau éthiopien aussi.

Le tributaire du Nil le plus au Nord est l'Atbara qui rejoint le Nil principal dans les régions des cataractes et contribue 12% du débit du Nil à Assouan. Son diagramme est concentré sur une saison plus courte (août - septembre). L'Atbara trouve ses sources au nord-ouest du plateau éthiopien.

La figure 2.6 représente deux sections longitudinales, une pour le Nil Blanc et l'autre pour le Nil Bleu. La figure 2.7 représente l'hydrogramme annuel à la station en amont du HBA avec la contribution moyenne de chacun des tributaires majeurs.




Figure 2. 6 : Sections longitudinales dans le Nil Blanc et dans le Nil Bleu (d'après Hillel, 1994).




Figure 2.7 : L'hydrogramme annuel à Assouan et la contribution moyenne des tributaires majeurs (d'après Hillel, 1994).

2.4 Variabilité interannuelle des débits du Nil

Les débits annuels du Nil ont excessivement fluctué que ce soit préhistoriquement ou dans les années récentes. Le Nil a connu des périodes substantielles de bas débits durant la dernière glaciation (autour de 20 milles ans, Williams et Faure, 1980) et durant la période de l'holocène (p. ex. de 1180 à 1350, Hassan, 1981). Les déclins des anciens royaumes pharaoniques sont associés à des périodes de bas débits (Bell, 1970). Riehl *et al.* (1979) montrent que les niveaux du Nil au Nilomètre de Roda (station de jaugeage du Nil près du Caire, cf. figure 2.5) n'ont jamais connu de stabilité tout au long de la série de données disponible depuis 622.

Durant le 20^{ème} siècle, une variabilité interannuelle substantielle des débits s'est produite avec un débit maximum de $120 \times 10^6 \text{ m}^3/\text{an}$ en 1916 et un minimum de $45,5 \times 10^6 \text{ m}^3/\text{an}$ en 1913. La séquence des plus bas débits (sur 5 ans de moyenne mobile) a eu lieu durant les années 80. La période récente de sécheresse au Sahel, qui a duré de 1965 jusqu'à 1987, a son homologue dans les débits du Nil Bleu et de l'Atbara. Conway et Hulme (1993) et Shahin (1990) ont montré une baisse statistiquement significative des débits (15%) pendant cette période comparée aux débits de 1945 à 1965 ou même à la moyenne à long terme. La figure 2.8 montre trois périodes, presque distinctes, dans les débits du Nil à Assouan de 1871 à 1989.




Figure 2. 8 : Variabilité des débits annuels à Assouan de 1870 à 1989.

Ces fluctuations ont donné lieu au fameux "phénomène de Hurst". La préoccupation de Hurst était de déterminer la capacité, à long terme, de rétention d'un réservoir. Il a découvert que la capacité du réservoir, qui pourrait assurer un prélèvement annuel moyen sur une série de débits de longueur d'années (n), est donnée par la relation:

$$\frac{R}{\sigma} = \left(\frac{n}{2}\right)^K \quad (2.1)$$

où R est la capacité du réservoir ou, en d'autres termes, la somme des départs cumulatifs de la moyenne (M) de la série chronologique

σ est l'écart type de la série

K est l'exponentiel de Hurst

n est le nombre d'année dans la série

Une distribution normale donnerait une valeur de $K = 0,5$. Hurst a trouvé que $K = 0.74$ pour les débits annuels du Nil à Assouan et qu'en général $K = 0,72$ en moyenne pour toutes les séries chronologiques naturelles étudiées (Hurst *et al.*, 1965).

La figure 2.9a illustre l'analyse de Hurst et de ses collaborateurs sur la série de 1870 à 1957. Evans (1994) a mis à jour l'analyse de Hurst et l'a étendue jusqu'en 1989 (figure 2.9b). Il a découvert que - du fait de la sécheresse persistante des années 70 et 80 - la capacité vive du lac Nasser, calculée à $30 \times 10^6 \text{ m}^3$, ne garantit qu'un débit moyen de $78 \times 10^6 \text{ m}^3/\text{an}$ au lieu de celui de $82 \times 10^6 \text{ m}^3/\text{an}$ calculé par Hurst sur la série jusqu'en 1957.

Le phénomène de Hurst constitue une énigme pour les chercheurs, d'autant plus que l'analyse des niveaux de la crue du Nil pour 1080 années au Nilomètre de Roda indique un non-rejet de l'hypothèse d'une distribution normale de leur fréquence. Plusieurs études ont essayé d'expliquer le phénomène de Hurst par des modèles et des arguments statistiques. Bras et Rodriguez-Iturbe (1985) attribuent le phénomène de Hurst à une ou plusieurs des causes suivantes :




Figure 2. 9 : Somme des départs cumulatifs de la moyenne de la série chronologique

a) d'après Hurst *et al.*, 1965

b) d'après Evans, 1994.

1. un comportement transitoire dû à de courtes séries d'observation (Salas *et al.*, 1979),
2. une non-stationnarité de la moyenne du processus (e. g, Klemeš, 1974; Potter, 1976; Boes et Salas, 1978), et
3. un processus stationnaire avec une très longue mémoire.

À la suite du travail pionnier de Hurst, les modèles stochastiques ont tenté de préserver les statistiques observées par Hurst. Plusieurs modèles ont été appliqués ou spécialement développés pour tenir compte de l'effet de longue mémoire (troisième explication du phénomène de Hurst) : le modèle de Bruit Gaussien Fractionné (FGN) (Mandelbrot et Wallis, 1969), le modèle fractionné autorégressif à moyenne mobile (FARMA) (Boes *et al.*, 1989) et la famille des modèles autorégressifs (AR) et autorégressifs à moyenne mobile (ARMA) (Yevjevitch, 1967; Hipel et McLeod, 1978).

2.5 Modèles de prévision des débits du Nil

Avant d'analyser en détail les modèles de prévision, les modèles stochastiques de Box et Jenkins utilisés pour la simulation des débits sont énumérés. Plusieurs modèles de type Box et Jenkins ont été utilisés pour la simulation des débits du Nil. Pour les débits annuels, Balek (1977) a ajusté un modèle ARMA d'ordre 13, Aguado (1987) un modèle ARIMA (2,1,1) et Shahin *et al.* (1993) un ARMA d'ordre 17 aux niveaux maximums. Reusing et Skala (1990), étudiant les sécheresses du Nil à partir de la série des niveaux au Nilomètre de Roda de 715 à 1470, construisent deux modèles ARMA et FGN. Les résultats d'analyse fréquentielle des durées de sécheresse montrent que le modèle FGN produit de plus longues durées de sécheresse pour une certaine probabilité d'occurrence. Pour générer les débits mensuels, Cury et Bras (1978) ont utilisé deux modèles: le modèle périodique PAR(1) multivarié et un schéma multivarié de type ligne brisée (*Broken Line*, BL) pour simuler les débits annuels qui sont ensuite désagrégés (D)

en débits mensuels. Une étude approfondie de la modélisation stochastique du Nil a été entamée dans le Master Plan for Water Resources Development and Use (1981) où on a comparé les modèles de Cury et Bras (1978) avec un modèle ARMA (1,1) avec désagrégation pour obtenir les écoulements saisonniers, et aussi un modèle AR (1) avec un bruit corrélé (Franchini *et al.*, 1985). En 1995, Salas *et al.* (1995) ont développé un modèle ARMA périodique de type "contemporain" (CPARMA (2,1)). C'est un schéma de modélisation multivarié où la matrice des paramètres est considérée comme étant diagonale. Le modèle CPARMA multiplicatif (CMPARMA) (1,0) est formulé et utilisé pour simuler les écoulements mensuels multivariés. Un modèle CMPARMA tronqué (TCMPARMA) est aussi utilisé pour simplifier l'estimation des paramètres. C'est le modèle TCMPARMA qui donne les meilleurs résultats. Il est utilisé actuellement pour la simulation des débits mensuels au ministère des Travaux Publics et des Ressources Hydriques (MTPRH) au Caire.

Comme le travail de recherche présenté dans cette thèse traite de la prévision des débits du Nil, la revue de littérature est centrée dans ce qui suit sur les modèles de prévision. Deux catégories distinctes de modèles ont été développées pour la prévision des débits du Nil à Assouan : les modèles statistiques / stochastiques (section 2.5.1) et les modèles distribués basés sur les propriétés physiques des bassins versants (section 2.5.2).

2.5.1 Modèles statistiques / stochastiques conçus pour la prévision

Les modèles statistiques / stochastiques développés pour la prévision du volume annuel à Assouan jusqu'à 1970 étaient de type "régression" au sens large du mot. Cela ne provient pas uniquement du manque de méthodes ou de données; mais surtout des résultats satisfaisants des équations de régression calculées sur la période "stable" (i.e. de faible variation) de 1912-1957 (Szalay, 1973; cité dans Shahin, 1990).

Durant les années 90, après la période persistante de sécheresse des années 80, plusieurs types de modèles de prévisions des débits du Nil à Assouan ont été développés. Dans la ligne des modèles ARIMA, El-Fandy *et al.* (1994) ont développé un modèle ARIMA (1,0,1)x(3,1,0) avec les données des niveaux d'eau au Nilomètre de Roda de 622 - 1021. Ce modèle est utilisé pour prédire les niveaux des années de 1022 à 1457. Aucune mesure statistique pour l'évaluation de la prévision n'est mentionnée dans l'article d'El-Fandy *et al.* (1994). En se référant à la figure de la page 91 (El-Fandy *et al.*, 1994), le modèle ne paraît pas bien prédire les extrêmes.

Pendant les mêmes années, Georgakakos *et al.* (1995a) ont appliqué trois techniques de prévision pour les débits mensuels à l'amont du haut barrage: le modèle du couloir (corridor model), deux modèles de réseaux de neurones et un modèle saisonnier de régression. Les trois modèles utilisent comme entrée les débits mensuels antérieurs à la station en amont du HBA sans d'autres variables exogènes. Ces modèles de prévision développés servent d'entrées à un modèle de contrôle et d'optimisation des prélèvements du HBA (Georgakakos *et al.*, 1995b, Georgakakos et Yao, 1997).

Le modèle du couloir "cherche" dans les données historiques et "choisit" plusieurs séquences de débits qui ont traversé les mêmes conditions que la séquence actuelle de débit. Chacune de ces séquences est une réalisation future probable de la séquence des débits. La longueur optimale du couloir est de trois mois. La valeur optimale pour la largeur du couloir (α) est de 0,8, ce qui indique un bruit élevé détecté dans la séquence du Nil. La figure 2.10 illustre les traces de débits produites par le modèle du couloir. La réduction de l'écart type (i.e. l'information additionnelle apportée par la prévision comparée à la variabilité de la série historique) est de 9% seulement en juin et juillet (Georgakakos *et al.*, 1995a).

Georgakakos *et al.* (1995a) ont également développé deux réseaux de neurones pour prédire les débits mensuels à Assouan. Le premier produit toute la séquence de débits, tandis que le second modèle est formé de 12 réseaux séparés, chacun pour prédire

les débits à un mois de l'année. Chacun des réseaux de neurones a 13 neurones sur la couche cachée.




Figure 2. 10 : Traces de volumes produites par le modèle du couloir
(d'après Georgakakos *et al.*, 1995a)

Le modèle de régression saisonnier consiste simplement en douze équations, une pour chaque mois. Chaque équation utilise les débits des 12 mois antérieurs pour prédire le débit du mois courant.

Chacun des trois types de modèle (le modèle du couloir, les réseaux de neurones, et la régression saisonnière) a des avantages et des lacunes. Le réseau de neurones pour la prévision saisonnière a les meilleurs résultats. Il a pourtant un nombre de paramètres plus grand que le nombre de données disponibles. Le modèle du couloir est le plus faible, mais il a l'avantage d'avoir deux paramètres seulement à ajuster et de

produire une gamme de débits et non une seule valeur; ce qui est très approprié à l'incorporation dans les modèles de contrôle.

Atiya *et al.* (1997) ont développé un réseau de neurones plus parcimonieux (trois neurones sur la couche cachée) pour prédire les débits moyens sur des périodes de dix jours. Les entrées du réseau sont les écoulements antérieurs, les écoulements aux mêmes périodes (pour les deux années précédentes), ainsi que la moyenne des écoulements des douze derniers mois.

Une observation commune aux modèles de Georgakakos *et al.* (1995) et Atiya *et al.* (1997) est que la capacité prévisionnelle de ces modèles a sa pointe en hiver mais chute en juillet/août. La difficulté est donc de prédire la crue du Nil Bleu qui commence en juillet. Même le meilleur modèle de Georgakakos *et al.* (1995), qui est le modèle saisonnier de réseaux de neurones, n'explique que 36 % de la variance du mois de juillet. Une fois le débit d'août connu, les modèles reprennent leur capacité de prédire le futur avec une précision raisonnable. Ces remarques suggèrent que l'information sur la crue du Nil n'est pas "cachée" dans les débits mensuels antérieurs, ni même dans la crue de l'an passé (vu la faible autocorrélation d'ordre 1 des débits du Nil Bleu ou de l'Atbara), mais qu'il fallait incorporer une variable exogène météorologique ou climatique.

2.5.2 *Modèle physique distribué : le système de prévision des débits du Nil (NFS)*

Le National Weather Service (NWS) américain (section du National Oceanic and Atmospheric Administration, *NOAA*) a développé un système de prévision des débits du Nil (Nile Forecasting System, NFS) au Haut Barrage d'Assouan (HBA). Le premier but de ce projet était de prédire le volume de ruissellement du Nil avec le plus d'avance

technique possible (Barrett, 1993). Les composantes du NFS sont illustrées dans la figure 2.11.




Figure 2. 11 : Système de prévision du Nil (version 3.0)

Le NFS reçoit les images qui proviennent du satellite METEOSAT toutes les 30 minutes et en produit une estimation des précipitations à l'aide d'une technique climatologique hybride développée par Schaake et Newby (1993). Les précipitations journalières sont interprétées en tenant compte de la probabilité de précipitation nulle, de la distribution asymétrique des pluies dans les journées pluvieuses, et de la structure de corrélation spatiale de la pluie (Schaake, 1993).

Une méthodologie a été développée pour prédire les débits à Assouan associés à leurs probabilités d'occurrence. Ceci est fait par deux modèles: un modèle stochastique

appelé la “prévision étendue des écoulements” (*Extended Streamflow Prediction, ESP*); et un modèle déterministe. La technique ESP utilise les valeurs des précipitations historiques; tandis que le modèle déterministe utilise des pourcentages fixes de la précipitation actuelle (Koren et Barrett, 1994). La figure 2.12 illustre la sortie de ce modèle.




Figure 2. 12 : Exemple de la sortie du modèle ESP (Koren et Barrett, 1994).

L'approche du NFS, qui est assez élaborée, originale et basée sur des concepts physiques, ouvre plusieurs pistes d'amélioration:

- utiliser des indices climatiques globaux représentatifs des forçages qui génèrent les champs atmosphériques sur la Corne de l'Afrique, pour prédire les précipitations avec un horizon de prévision plus grand. Ceci a été réalisé en partie par Lin (1995 a, b

et c) mais son modèle n'explique que 36% de la variabilité de la précipitation annuelle sur le HPE (cf. section 2.6.2 (b))

- incorporer les mêmes indices en guise d'information additionnelle pour "biaiser" les probabilités d'occurrence des débits vers une valeur plus précise.

2.6 Fluctuations des débits et forçage climatique

Les fluctuations déjà remarquées dans les débits reflètent une variabilité de processus naturels et anthropogéniques. Ces processus opèrent sur différentes échelles temporelles comme le montre la figure 2.13 (adaptée de Hulme, 1994). Le cycle solaire a été ajouté au diagramme de Hulme (1994). Il est à noter que ce signal est plus présent dans les pluies à mousson dans les régions arides ou semi-arides où le signal solaire de nuages n'est pas masqué. Seleshi *et al.* (1994) ont essayé à l'aide d'une fonction de transfert avec bruit (FTB) de prédire la pluie à Addis-Abeba (Éthiopie) à partir du nombre de tâches solaires.

Peu de ces facteurs identifiés séparément sont vraiment indépendants. Par exemple, l'ENSO détermine en partie les caractéristiques du jet tropical de l'est (JTE) et la position en altitude de la zone de convergence intertropicale (ZCIT). De plus, l'échelle temporelle sur laquelle chaque variable est identifiée est assez approximative. Néanmoins, le diagramme (figure 2.13) permet de montrer la complexité et la hiérarchie des facteurs qui déterminent la précipitation du bassin du Nil en une certaine année.

Notons que la variabilité des cycles orbitaux opère sur une échelle millénaire et dépasse par conséquent l'étendue de cette thèse. De plus, la réponse de la précipitation régionale aux sources du Nil à l'augmentation de CO₂ dans l'atmosphère (l'effet de serre) est assez incertaine (Conway et Hulme, 1996 ; et Conway et al, 1996).




Figure 2.13 : Forçages climatiques agissant sur les précipitations du bassin du Nil (d'après Hulme, 1994).

L'impact des conditions climatiques telles que l'ENSO, le changement des températures de surface des océans (TSO), l'amplitude du JET, et la position de la ZCIT sur les débits du Nil sont les facteurs responsables en grande partie de la variabilité pluviométrique interannuelle sur le bassin du Nil. Le plus important est l'ENSO. Une description de ce phénomène suit.

2.6.1 Description de l'ENSO

L'ENSO ou El-Niño / Southern Oscillation, comme l'indique son nom composé, est un phénomène double : le courant maritime El-Niño et l'Oscillation Australe.

- El-Niño est un phénomène d'anomalies chaudes de températures (au moins de 0,5°C) le long de la côte du Pérou et de l'Équateur (Amérique Latine) dans l'est du Pacifique. Le nom d'El-Niño (avec un N majuscule) se réfère au Christ Enfant parce que ce courant apparaît autour de Noël (l'été austral). La côte occidentale de l'Amérique du Sud expérimente un courant maritime froid durant cette période de l'année. Le réchauffement El-Niño dure au moins trois saisons, généralement de 12 à 18 mois. Il s'étend au Pacifique équatorial de 160°W et jusqu'à la côte de l'Amérique du Sud (Kiladis et van Loon, 1988) (figure 2.14).




Figure 2. 14 : Anomalies chaudes au Pacifique durant la phase El-Niño (d'après NOAA/OGP, 1992).

- L'Oscillation Australe concerne, avant tout, les anomalies de la circulation zonale dans le domaine indo-pacifique. Sir Gilbert Walker a été le premier à rapporter une corrélation négative entre la pression de surface de la mer (SLP) à Tahiti (Polynésie Française) et celle à Darwin (Australie) (Walker, 1923). Cette corrélation forme une oscillation de type dents de scie. L'Oscillation Australe est une circulation qui associe un renforcement (ralentissement) des alizés à une augmentation (diminution)

des ascendances sur l'Indonésie et de la subsidence sur le Pacifique est. Vu la complexité de cette circulation, plusieurs indices sont proposés pour la quantifier. L'indice le plus utilisé est celui de la différence entre la pression à Tahiti et à Darwin (Southern Oscillation Index, SOI).

Bjerkens (1969) a lié les deux phénomènes suggérant un couplage océano-atmosphérique. Dans cette thèse, le terme ENSO est utilisé pour désigner l'ensemble des mécanismes en jeu. Les deux phases extrêmes de ce mode couplé seront désignées par "phase La-Niña" (haute pression atmosphérique et froides anomalies au Pacifique) et "phase El-Niño" (basse pression atmosphérique et chaudes anomalies au Pacifique) (figures 2.15 a et b).




Figure 2. 15 : Représentation schématique de la circulation de Walker

a) année normale

b) phase El-Niño.

L'Oscillation Australe n'a pas de cycle fixe, mais enregistre des périodicités entre 2 et 10 ans (Glantz, 1996). Il a été démontré que l'ENSO a un mode biennal, se

propageant d'ouest en est, de l'Océan Indien oriental vers le centre du Pacifique (Barnett, 1991; Ropelewski *et al.*, 1992).

Les téléconnexions de l'ENSO sont multiples et font de lui le mode majeur de la variabilité climatique interannuelle dans la zone intertropicale. L'impact climatique de l'ENSO a été étudié aux échelles indo-pacifique (Rasmussen et Carpenter, 1982; Kiladis et van Loon, 1988; ...), tropicale ou planétaire (Walker et Bliss, 1932; Ropelewski et Halpert, 1987; Trenberth, 1991; ...).

L'importance de l'ENSO vis-à-vis des variations climatiques intertropicales tient aux particularités suivantes (Camberlin, 1994) :

- il est un mécanisme qui implique des masses atmosphériques et océaniques considérables, et l'amplitude des anomalies générées est très forte au regard de la variabilité climatique intertropicale;
- il concerne d'une manière cohérente l'ensemble des composantes océano-atmosphériques de la région indo-pacifique (pression, vents de surface et d'altitude, températures de surface d'océans (TSO), convection, précipitations, ...); et
- il est très persistant d'un mois à l'autre. Cette persistance permet d'étendre l'horizon de prévision basé sur les indices d'ENSO.

Après cette brève description de l'ENSO, les études, qui ont relié les forçages climatiques aux différents éléments hydrométéorologiques du bassin du Nil, seront passées en revue dans ce qui suit.

2.6.2 Prévision à partir d'informations climatiques

Durant les quinze dernières années, les travaux se sont multipliés sur les connexions entre, d'une part, la variabilité pluviométrique (surtout interannuelle) dans le Sahel, l'Inde et l'est de l'Afrique, et d'autre part, la dynamique océano-atmosphérique.

Le plus grand nombre de recherches a porté sur l'impact des événements ENSO sur les précipitations.

Pour mieux classer ces travaux, une distinction s'avère importante entre les études "diagnostiques" et celles de "prévision". Le terme "prévision" devrait s'appliquer uniquement à une déclaration sur un événement, déduite d'une information sur des conditions antécédentes. Par conséquent, toute relation entre des variables concurrentes est plus de genre diagnostic que prévisionnel.

Les études et les modèles de prévision peuvent être à leur tour subdivisés en (Hastenrath, 1986) :

- modèles numériques qui simulent les équations de circulations générales;
- modèles statistiques / stochastiques, où l'entrée n'est autre que les variables à prédire: modèles ARMA, analyse théorique de périodicités, ...; et
- modèles statistiques / stochastiques où les entrées sont des variables météorologiques autres que la sortie. Ces modèles peuvent être divisés en deux sous-groupes :
 - * modèles de persistance où par exemple des valeurs de précipitations dans une région X sont utilisées pour prédire les précipitations de la région Y.
 - * modèles qui combinent les diagnostics de circulations générales et les méthodes statistiques. La démarche, pour construire ce type de modèle de prévision, consiste en cinq étapes, comme le montre la figure 2.16.



Figure 2.16 : Modèle de prévision statistique qui incorpore les informations climatiques

La présente revue de littérature porte surtout sur ce dernier type d'approche. Elle met l'emphasis sur les régions des sources du Nil mais inclut d'importants résultats du Sahel et de l'Inde. La sous-section 2.6.2.1 passe en revue les méthodes utilisées et la sous-section 2.6.2.2 dégage les résultats.

2.6.2.1 *Méthodes utilisées*

Les modèles numériques utilisés sont des modèles de circulations générales (*Global circulation model*, GCM). Ils sont rarement utilisés pour prédire des pluies régionales, mais un groupe de chercheurs au bureau météorologique britannique (*UK Meteorological Office*, UKMO) a utilisé avec succès un modèle GCM pour étudier le forçage océanique des précipitations du Sahel.

Pour les modèles statistiques "purs", ce sont les analyses des séries temporelles avec l'approche de Box et Jenkins ou bien celle de l'analyse spectrale. Ces méthodes souffrent de la limite des séries utilisées pour déduire les tendances et les périodicités. L'exemple connu est celui du fameux article de Faure et Gac (1981 a et b) qui, analysant une courte période des débits du fleuve Sénégal, concluent l'existence d'une périodicité de 30 ans et font une inférence de terminaison de la sécheresse du Sahel en 1985 et des années normales depuis 1992. Cependant, ce qui s'est produit est que l'année 1987 comptait parmi les plus sèches et la sécheresse a duré pendant les années 1990.

Quant aux méthodes statistiques utilisées, on retrouve essentiellement les méthodes de régression simple ou multiple pour vérifier la relation entre les variables, que le but soit diagnostic ou prévisionnel. Pour l'analyse multivariée, la méthode prédominante est l'analyse en composantes principales. Une fois les modes de variation connus, les relations avec les autres variables sont analysées par les méthodes de régressions linéaires. Cette approche est essentiellement diagnostique.

Peu d'études analysent l'aspect non linéaire des relations. Thapliyal et Kulshrestha (1992) ont utilisé la régression de puissance (Power Regression) et Navone et Ceccatto (1994) ont construit un modèle de réseaux de neurones pour la prévision des pluies en Inde. Ceci est dû, non seulement à la complexité relative des modèles non linéaires, mais aussi au fait que ceux-ci nécessitent des séries de données plus longues pour bien caler les modèles, condition rarement satisfaite dans la plupart des études portant sur la variabilité interannuelle.

2.6.2.2 Résultats des recherches

Relations avec les cycles solaire et lunaire

Wood et Lovett (1974) ont proposé une prévision des pluies d'Addis-Abeba en Éthiopie basée sur le cycle solaire de 11 ans. Depuis l'an 1066, 72% des sécheresses se sont produites dans un intervalle de 2 ans avant et un an après le minimum de taches solaires. D'autre part, des variations de 11 ans ont été trouvées dans les niveaux du lac Victoria (Brooks, 1928). Cette périodicité est controversée car elle n'apparaît pas au milieu du siècle (Hurst, 1957).

Plus récemment, Hameed (1984) et Currie (1987), analysant la crue d'été du Nil, ont trouvé deux pics : l'un à 19,8 ans et l'autre à 10,8 ans. Selon Currie (1987), le premier pic, présent dans un grand nombre de paramètres météorologiques, résulterait d'un forçage lunaire de 18,6 ans; tandis que le cycle de 11 ans est celui de l'activité solaire. Seleshi *et al.* (1994) utilisent le nombre de taches solaires pour prédire à l'aide d'une fonction de transfert avec bruit les pluies d'Addis-Abeba.

Relations avec les indices de l'ENSO en particulier et avec les Températures de Surface des Océans (TSO) en général

- * Walker et Bliss (1932) et Bliss (1932) étaient les premiers à relier l'ENSO aux débits du Nil. Ils ont utilisé la crue du Nil parmi 10 variables pour construire un

indice de l'ENSO. Dans les années 90, Anderson (1992), Quinn (1992), Whetton et Rutherford (1994) et Eltahir et Wang (1999) ont construit une chronologie des événements ENSO depuis le septième siècle, à partir des niveaux d'eau au Nilomètre de Roda.

- * À l'échelle annuelle, Nicholson et Entekhabi (1986) ont trouvé une relation positive entre les précipitations du haut plateau kenyo-ougandais et les phases El-Niño, mais la cohérence entre les deux phénomènes apparaît seulement dans la bande spectrale de 2,2 à 2,4 ans. Plus précisément, la relation entre l'ENSO et les pluies sur le plateau Kenyo-Ougandais change de signe avec la saison. En été boréal, les pluies déficitaires sont liées aux phases El-Niño (Janowiak, 1988; Ogallo, 1988). En automne boréal, les pluies excédentaires sont liées aux mêmes événements (Ropelewski et Halpert, 1987; Farmer, 1988; Ogallo, 1988; Beltrando, 1990; Hutchinson, 1992). Au printemps boréal, les relations sont médiocres. Ceci est expliqué par Hastenrath (1991). Les variations interannuelles sont liées aux anomalies de TSO dans le Pacifique équatorial est et dans l'ouest de l'océan Indien, ainsi qu'à un indice zonal de pression calculé par la différence entre la pression à Darwin et celle de l'Afrique de l'est (Camberlin, 1994).
- * Les connexions ENSO avec les pluies d'Éthiopie et les débits de l'Atbara et du Nil Bleu ont fait l'objet de la plupart des travaux de type diagnostic (Flohn, 1987; Janowiak, 1988; Bhatt, 1989; Attia et Abulhoda, 1990; Seleshi et Démarée, 1995; Camberlin, 1993 et 1997; Gissila, 1997). Les corrélations sont négatives et significatives avec les TSO, quoique quelques années semblent ne pas se conformer à ce schéma (p. ex. 1976-77 et 1984). La stabilité des relations entre l'ENSO et les précipitations estivales au nord de la Corne africaine est un point de controverse entre les études : Camberlin (1997) affirme cette stabilité; tandis que Flohn (1987), entre autres, signale une dégradation des relations avec le Sahel pendant la période de 1900 à 1940.

- * Dans une étude sur les débits du Nil, Attia et Abulhoda (1990) ont établi, par analyse composite, une association significative entre les phases ENSO et les bas débits de l'Atbara et du Nil Bleu pendant la période de 1914 à 1988.
- * Bhatt (1989) a utilisé les mêmes séries de débits du Nil, mais de 1914 à 1973. Il montre l'existence de corrélations négatives avec les TSO de juillet dans le nord-ouest de l'océan Indien (conforme aux résultats de Beltrando et Camberlin (1993) avec la série de pluies) et d'un dipôle nord-sud dans l'Atlantique. Ce dernier résultat, qui reflète l'importance de la position de la ZCIT pour les précipitations aux sources du Nil Bleu, est conforme aux résultats empiriques (p. ex. Lamb et Pepler, 1991; Rowell *et al.*, 1995) ainsi que ceux des modèles numériques du UKMO pour les précipitations au Sahel (Folland *et al.*, 1986; Palmer, 1986; Druyan, 1988; Parker *et al.*, 1988; Folland *et al.*, 1991).

Les études à caractère prévisionnel sont restreintes pour les précipitations sur le HPE.

- * Lin (1995 a, b et c) a analysé les corrélations croisées entre la Précipitation sur l'Aire Moyenne (PAM) du bassin du Nil Bleu et 13 indices de l'ENSO, dont l'indice de l'Oscillation Australe (SOI) et les températures de surface du Pacifique dans les régions Niño 2 à 4, pendant les mois d'avril à juin qui précèdent la crue du Nil. Deux résultats importants se dégagent de cette étude :
 1. L'analyse des autocorrélations des données mensuelles des divers indices de l'ENSO indique une baisse brusque des coefficients au printemps. Le signal climatique de l'ENSO ne persiste pas à un mois donné, laissant place au nouveau cycle annuel qui commence. Ceci est connu sous le nom de la discontinuité de printemps (*Spring break*). Chaque indice possède sa propre date de discontinuité. Celles-ci sont illustrées à la figure 2.17.




Figure 2. 17 : Différents indices de l'ENSO et leurs discontinuités de printemps
(d'après Lin, 1995a)

2. La PAM du bassin du Nil Bleu est plus corrélée, au pas de temps mensuel, avec la région du Niño 3. Le tableau 2.1 et les figures 2.18 a à d résument les corrélations plus importantes trouvées par Lin (1995 a, b, et c).

Tableau 2. 1 : Corrélations entre la PAM du Nil Bleu et différents indices de l'ENSO

	Niño 3 avril	Niño 3 mai	Darwin SLP mai	Niño 3 et SLP avril et mai
PAM de juillet	-0,440	-0,046		0,480
PAM de septembre	-0,050	-0,066	0,360	0,710
PAM des 3 mois JAS		-0,640	0,390	0,650




Figure 2. 18 : Relations linéaires entre la PAM au Nil Bleu et différents indices de l'ENSO (Lin, 1995b)

- * Eltahir (1996) et Amaresekera *et al.* (1997) ont établi, par régression linéaire, que la relation, entre un indice de l'ENSO proposé par Wright (1989) et les débits annuels du Nil principal, explique 25% de la variabilité interannuelle de ces débits. Eltahir (1996) suggère que la variabilité de l'ENSO soit la cause de la non-stationnarité de la moyenne des débits annuels à Assouan et par la suite donnant lieu au phénomène de Hurst. Les fluctuations, qui ont lieu autour de cette moyenne variable, seraient

dues à des facteurs climatiques, hydrologiques ou anthropiques autres que l'ENSO. Eltahir (1996) propose une relation linéaire entre la moyenne des débits annuels du Nil à Assouan et les TSO au Pacifique équatorial avec un coefficient de corrélation de $-0,9$.

- * Wang et Eltahir (1999) utilisent une approche bayésienne pour prédire une estimation approximative du volume du ruissellement du Nil à Assouan (crue abondante, moyenne, ou déficiente). La prévision est évolutive : avant juin de l'année de crue, seule l'information climatique est utilisée comme entrée, en juin les précipitations sont incorporées et en juillet, les écoulements de juin sont ajoutés au modèle ; ainsi l'information est utilisée au fur et à mesure qu'elle est disponible.
- * Seleshi (1997) utilisant une fonction de transfert avec bruit (FTB) propose un modèle pour les pluies en Éthiopie incorporant divers indices climatiques (figure 2.19). Le modèle de FTB explique plus de 60% de la variabilité pluviométrique, mais il souffre de plusieurs lacunes :
 - il est peu parcimonieux, possédant 5 entrées et 13 paramètres à estimer, et
 - la composante de retard (3 ans) associée au nombre de taches solaires et celle de 2 ans associée aux TSO de l'océan Indien sont difficiles à expliquer.
- * Camberlin (1994) propose ce schéma pour expliquer l'interaction entre les précipitations d'été boréal sur toute la Corne de l'Afrique et la circulation océano-atmosphérique (figure 2.20). Le schéma est assez complexe et difficile à modéliser au complet dans un cadre prévisionnel, vu les relations de feed-back qui existent entre la plupart des éléments du système. Néanmoins, il donne une bonne indication des générateurs de la précipitations sur le HPE (PRECIP. NORD, sur le graphique)




Figure 2. 19 : Modèle de FTB pour prédire les pluies en Éthiopie (Seleshi, 1997)




Figure 2. 20 : Connexions avec les variations interannuelles des précipitations d'été dans la Corne de l'Afrique et la circulation océano-atmosphérique (Camberlin, 1994).

2.7 Discussion générale et méthodes proposées

2.7.1 *Remarques sur les résultats dégagés de la revue de littérature*

- Plusieurs remarques émanent de l'analyse des résultats des études déjà citées dans cette revue de littérature sur la simulation et la prévision des débits du Nil :
 - * le regroupement des années sèches et humides rend difficile la modélisation pour la simulation ou la prévision et suggère l'existence d'une relation avec les conditions climatiques persistantes ;
 - * le volume de la crue du Nil Bleu est difficile à prédire par l'analyse des séries temporelles et la régression, si seuls les écoulements antérieurs sont utilisés.
- Les études ont essayé de trouver la relation entre les débits à Assouan et les indices de l'ENSO ou même de construire la chronologie de l'ENSO à partir des niveaux d'eau au Nilomètre de Roda près du Caire. Une telle approximation néglige que ces écoulements proviennent des précipitations sur plusieurs sources qui sont différemment corrélées avec l'ENSO. Il est donc suggéré que toute nouvelle approche, pour quantifier l'apport du bassin du Nil, distingue entre les différents circulations et régimes dominant les bassins versants du Nil Blanc et du Nil Bleu (Evans, 1994). Les observations sur les deux dernières décennies fournissent l'évidence, en cas de besoin, de l'importance de traiter les Nils Bleu et Blanc séparément ou au moins de développer des modèles de prévision saisonnière.
- Les chercheurs étudient la relation des précipitations avec une seule variable (le SOI par exemple). Pourtant, comme déjà cité, les précipitations de la Corne de l'Afrique dépendent à la fois de deux composantes de circulations: la composante de Hadley (qui influence la position de la ZCIT) et celle de Walker (comme le SOI).
- Aucune des approches n'utilise l'information cachée dans les données de la variable de sortie (périodicités, structure d'autocorrélation, ...) avec l'information apportée

par les facteurs climatiques. Ceci est possible surtout à l'aide des modèles de fonctions de transfert avec bruit.

2.7.2 Remarques sur les méthodes dans la revue de littérature

Comme déjà remarqué, la régression linéaire est utilisée dans la plupart des études de prévision de type "forçage climatique – précipitations ou débits". Cette approche souffre de plusieurs lacunes (Tabios et Salas, 1982). La plupart des études analysées ne prenaient pas en considération :

- l'autocorrélation de la série des entrées et aussi celle des sorties: celle-ci réduit les degrés de liberté et suggère des relations là où il n'y en a pas;
- la collinéarité des variables d'entrée dans la régression multiple; et / ou
- la validation des relations: celle-ci doit être faite sur un ensemble de données différent de celui qui a servi à estimer les paramètres de l'équation de régression.

Des modèles plus structurés, tels que les fonctions de transfert avec bruit (FTB) et les modèles autorégressifs à moyenne mobile avec variable(s) exogène(s) (*Autoregressive moving average with exogenous variable*, ARMAX), permettent (Brown et Katz, 1991) :

- une interprétation relativement directe des fonctions de corrélation croisée entre les séries temporelles,
- une considération de plusieurs variables simultanément,
- la modélisation des structures de dépendances temporelles plus complexes qui agissent sur des échelles de temps différents, et
- une représentation autocorrélée du bruit.

D'autre part, la régression linéaire n'est pas appropriée si la relation entre les entrées et les sorties n'est pas linéaire. Ceci est commun en hydrologie et en météorologie. Voici quelques exemples de relations non linéaires:

- la relation pluie-ruissellement: le ruissellement commence lorsque la précipitation dépasse le seuil de la somme de l'évaporation et de l'infiltration. C'est le cas d'un phénomène qui ne se produit que si l'événement générateur dépasse un certain seuil.
- les crues et les sécheresses : c'est le cas d'un phénomène où les deux extrêmes n'agissent pas de la même manière.
- la persistance de la sécheresse: la précipitation augmente l'humidité du sol qui à son tour augmente l'évaporation et par suite la précipitation formant une boucle. C'est le cas d'un système à feed-back.

Ces exemples très communs en hydrologie suggèrent l'utilisation de modèles plus adaptés aux relations non linéaires. Il a été démontré par Nemec et Schaake (1982), Gleick (1987) et Schaake (1990) que la réponse du ruissellement à un changement de précipitation est très non linéaire et que la non-linéarité est plus grande dans les climats arides. Les réseaux de neurones artificiels (RNA) introduisent une relation non linéaire entre les entrées et les sorties. Les deux sections qui suivent définissent les FTB et les RNA et énumèrent leurs applications dans le domaine de l'hydrologie. Une présentation plus complète des deux méthodes figure au chapitre III ainsi que comment elles sont appliquées dans ce travail de recherche.

2.7.3 Fonctions de transfert avec bruit

Une fonction de transfert avec bruit *additionné* (*Transfer function with added noise*, ou fonction de transfert avec bruit (FTB)) est un modèle stochastique qui possède une ou plusieurs variables exogènes à l'entrée. Les *relations temporelles* entre celles-ci et la (ou les) sortie(s) sont modélisées mathématiquement. Qualitativement, un modèle de FTB à *une* sortie pourrait être formulé comme :

$$\text{Sortie} = \text{composante dynamique} + \text{bruit} \quad (2.2)$$

La manière par laquelle chacune des séries d'entrée (X_{it}) incorporées dans le modèle affecte la série de sortie (Y_t) est modélisée par la composante dynamique. Le bruit tient compte de tous les autres influences qui ne sont pas pris en compte par la composante dynamique.

Les fonctions de transfert avec bruit ont été largement utilisées en hydrologie pour des applications allant de la modélisation de la relation précipitation–ruissellement (Anselmo et Ubertini, 1979; Anselmo et al., 1982; Baracos *et al.*, 1981; Hipel *et al.*, 1982; Moore, 1982; Thompson *et al.*, 1983; Snorrason *et al.*, 1984; Noakes *et al.*, 1985; Thompson *et al.*, 1985; Snorrason et Einarsson, 1986; Fay *et al.*, 1987; McLeod *et al.*, 1987; Haltiner et Salas, 1988 ; Novotny et Zheng, 1990) à la prévision des débits connaissant les débits antérieurs (Olason et Watt, 1986; El-Sayed et Errih, 199), à la modélisation du transport de sédiments et la qualité des eaux (Laukkanen, 1986), à l'évapotranspiration (Hameed *et al.*, 1995) et à la modélisation de la fluctuation de la nappe souterraine (Knotters et van Walsum, 1997; Knotters et De Gooijer, 1999). Delleur (1986) a démontré qu'un modèle de FTB est en fait la version discrète dans le temps des équations différentielles continues dérivées des principes de conservation de masse et de celle de la quantité de mouvement.

2.7.4 Réseaux de neurones artificiels

Historiquement, l'intérêt pour le domaine des réseaux de neurones artificiels (RNA) a débuté avec les travaux de Neumann, Turing, McCulloch, Minsky et Pitts. Il a émergé du désir de construire un système artificiel capable de reproduire certaines des fonctionnalités intelligentes du cerveau humain, telles que l'apprentissage de tâches complexes, la généralisation et les capacités de raisonnement et de déduction. La structure des RNA tente d'imiter le cerveau humain en plusieurs aspects :

- Les RNA sont des réseaux avec plusieurs unités simples (dites *neurones*) qui sont liées par des *connexions* et qui opèrent exclusivement sur les entrées qui leur parviennent.
- Les poids de ces connexions sont déterminés par *apprentissage*. Celui-ci se fait par essais et erreurs comme un enfant qui apprend à soulever un poids sans pour autant comprendre les lois de gravité de Newton.
- Les RNA sont des processeurs *parallèles* puisque les calculs dans les neurones sont largement indépendants les uns des autres.

C'est en 1943 que McCulloch et Pitts (1943) ont formulé le modèle du neurone, utilisé jusqu'à maintenant. Rosenblatt (1962) a rassemblé plusieurs neurones, avec des fonctions à seuil, sur deux groupes d'entrée et de sortie et a proposé une règle pour ajuster itérativement les paramètres des neurones (les valeurs des poids et des seuils). Un peu plus tard, Minsky et Papert (1969) ont démontré l'incapacité du modèle de Rosenblatt d'apprendre une fonction aussi simple que le "ou-exclusif" ou tout autre patron de discrimination entre deux ensembles non linéairement inséparable.

Werbos (1974) et puis Rumelhart *et al.* (1986) ont ouvert la voie aux réseaux de neurones par la mise au point du perceptron multicouches et de l'algorithme de rétropropagation permettant d'ajuster, par un simple calcul de dérivées, les poids et seuils des neurones pour satisfaire un critère de minimisation d'une fonction d'erreur. C'est ce type de RNA qui est le plus utilisé pour la prévision. L'exposé plus détaillé des RNA au chapitre III porte sur le perceptron multicouches.

Daniell (1991) fut le premier à utiliser les RNA en hydrologie. Il cite dix applications potentielles des RNA dans le domaine des sciences de l'eau. Certaines de ces applications ont connu plus de succès que d'autres :

- la modélisation de la relation pluie-ruissellement surtout pour la prévision à court terme (1 à 7 jours) utilisant des données générées (Smith et Eli, 1992 ; French *et al.*, 1992 ; Smith et Eli, 1995 ; Minns et Hall, 1996) ou utilisant des données réelles

- (Crespo et Mora, 1993 ; Zhu *et al.*, 1994 ; Anmala *et al.*, 1995 ; Ichyanagi *et al.*, 1995 ; Hsu *et al.*, 1995 ; Dimoupoulos *et al.*, 1996 ; Mason *et al.*, 1996 ; Dawson et Wilby, 1998),
- la prévision de débits provenant de la fonte de neige (Markus *et al.*, 1995 ; Ribeiro-Corréa *et al.*, 1995 ; Birikundavyi *et al.*, 1999)
 - la prévision des débits connaissant les débits antérieurs ou des débits à d'autres sites (Karunanithi *et al.*, 1994 ; Raman et Sunilkumar, 1995 ; Atiya *et al.*, 1997 ; Thirumalaiah et Deo, 1998)
 - la prévision de la qualité de l'eau (Daniel et Wundke, 1993 ; Maier et Dandy, 1994)
 - la prévision de la consommation en eau (Daniell, 1991 ; Zhang *et al.*, 1994 ; Fleming, 1994)
 - l'optimisation multi-objective (Wen et Lee, 1998) et la prise de décisions sujette à l'incertitude (Hara *et al.*, 1994 ; Basheer *et al.*, 1996).

Malgré le succès de leurs applications en hydrologie, les RNA ont suscité beaucoup de critiques, parce qu'ils sont des modèles de boîte noire, et qu'il leur manque une méthodologie de validation rigoureuse (De Marsily, 1994). Fortin *et al.* (1997) rejette l'utilisation des RNA pour la prévision hydrologique, sous prétexte qu'elles n'offrent pas de mesure pour quantifier l'incertitude associée à la prévision. Ces critiques, bien que fondées, ne sont pas aussi absolues qu'elles le paraissent, comme cela sera montré dans les chapitres qui suivent.

Il est important de signaler ici qu'aucune des applications des FTB ou des RNA passées en revue dans la littérature n'a modélisé directement la relation entre les variables climatiques et les débits dans un but prévisionnel.

Chapitre III

MÉTHODOLOGIES DE RECHERCHE

3.1 Introduction

Le but de ce chapitre est d'exposer le fondement théorique et le développement des deux méthodes de prévision proposées dans ce travail de recherche : les fonctions de transfert avec bruit additionné (ou fonction de transfert avec bruit, FTB) et les réseaux de neurones artificiels (RNA). Comme déjà mentionné dans le chapitre II, les modèles de régression linéaire, couramment utilisés en climatologie pour la prévision à moyen terme, sont incapables de modéliser la structure dynamique entre les variables d'entrée et de sortie ; de plus, ils n'offrent pas une représentation autocorrélée du bruit. Les FTB sont une extension de la régression linéaire multiple qui tient compte des lacunes mentionnées ci-dessus. Les modèles de RNA, qui ont émergé du domaine de l'intelligence artificielle, généralisent les FTB, explorant la non-linéarité des relations entre les entrées et les sorties. La supériorité des FTB et des RNA est démontrée en comparant leurs résultats (chapitre V) à ceux obtenus par régression linéaire (cf. section 4.5).

Ce chapitre est organisé en deux grandes sections qui suivent celle de l'introduction : la section 3.2 est consacrée aux FTB et la section 3.3 aux RNA. La présentation de chacune des deux méthodes porte sur leurs formulations et hypothèses de base, suivies des algorithmes pour la construction des deux modèles. Elle est centrée sur l'utilisation des deux méthodes en prévision et une attention spéciale est portée sur la quantification de l'incertitude des prévisions (cf. sections 3.2.6 et 3.3.8). Les hypothèses des FTB permettent de construire des limites de confiance théoriques pour les prévisions, tandis que les limites de confiance pour les prévisions des RNA sont construites en utilisant une technique de bootstrap.

3.2 Fonctions de Transfert avec Bruit (FTB)

3.2.1 Présentation et formulation générale

Une fonction de transfert avec bruit additionné (*Transfer function with added noise* ou fonction de transfert avec bruit (FTB)) est un modèle de type Box et Jenkins (1976) qui possède une ou plusieurs variables exogènes à l'entrée. Il est dit *modèle de régression dynamique*, car les *relations temporelles* entre les variables d'entrée et de sortie y sont modélisées. En guise d'exemple, un modèle stochastique peut être développé pour modéliser la relation mathématique entre la série de débits et une ou plusieurs séries de variables exogènes, telles que les précipitations ou les températures. La modélisation par FTB suit les trois étapes de l'approche classique de Box et Jenkins (1976) (figure 3.1), soit :

- l'identification du modèle (pour déterminer la structure du modèle, i.e. le nombre et l'ordre des paramètres de la relation dynamique entre les variables exogènes et les sorties, ainsi que la modélisation du bruit) ;
- l'estimation de ses paramètres ; et
- la validation du modèle.

Cependant, avant de procéder à la construction des FTB par les trois étapes précédentes, chacune des séries (X_{it}) des variables exogènes (séries d'entrées) doit être modélisée par le modèle de type Box et Jenkins (1976) le plus approprié. Le cas général de ce type est le modèle autorégressif intégré avec moyenne mobile (*Autoregressive integrated moving average*, ARIMA) le plus approprié. Les résidus (u_{it}) de ces modèles ARIMA sont appelés les *innovations* des variables exogènes. Ces innovations servent à l'identification des FTB et à leur validation. Pour éviter toute ambiguïté dans cette thèse, le terme *innovations* est restreint aux résidus des séries de sortie et d'entrées,

tandis que le terme *résidus* est restreint aux différences entre les valeurs observées et celles prédites dans les différents modèles de prévision construits par FTB ou RNA.




Figure 3. 1 : Représentation des étapes de construction d'un modèle de Box et Jenkins
(d'après Salas *et al.*, 1980)

Comme déjà mentionné à la section 2.7.3, une FTB comprend deux composantes : une composante dynamique, qui modélise la relation entre chacune des variables exogènes (X_{it}) incorporées dans le modèle et la variable de sortie (Y_t) ; et une composante de bruit, qui tient compte de toutes les autres influences qui ne sont pas prises en compte par la composante dynamique. Le texte qui suit présente les paramètres à estimer pour ces deux composantes.

3.2.1.1 Composante dynamique

La composante dynamique qui relie m entrées à la sortie est de type :

$$\text{Composante dynamique} = \sum_{i=1}^m V_i(B) X_{it} \quad (3.1)$$

Les coefficients v_i du polynôme V_i sont nommés les *poids de la fonction de transfert* ou les *poids de la fonction impulsion-réponse* de la $i^{\text{ème}}$ série d'entrée (X_{it}). Par souci de parcimonie, la fonction impulsion-réponse pourrait être formulée par le rapport :

$$\begin{aligned} V_i(B) &= v_0 + v_1 B + v_2 B^2 + \dots \\ &= \frac{\Omega_i(B)}{\Delta_i(B)} B^{b_{\min}}, = \frac{(\omega_{i0} - \omega_{i1} \cdot B - \dots - \omega_{is} \cdot B^s)}{(1 - \delta_{i1} \cdot B - \dots - \delta_{ir} \cdot B^r)} B^{b_{\min}}, \end{aligned} \quad (3.2)$$

où

$\Omega_i(B)$ est l'opérateur du numérateur de la $i^{\text{ème}}$ entrée et ω_{ij} est le paramètre du numérateur au délai j de l'entrée i ,

$\Delta_i(B)$ est l'opérateur du dénominateur de $i^{\text{ème}}$ entrée, et δ_{ij} est le paramètre du dénominateur au délai j de l'entrée i , et

B^k est l'opérateur de translation – arrière au délai k , défini comme

$$B^k X_t = X_{t-k} \quad (3.3)$$

s_i et r_i sont respectivement les ordres des opérateurs du numérateur et du dénominateur de la fonction impulsion-réponse associée à la série d'entrée X_{it} , et $bmin_i$ est le décalage requis avant que la série d'entrée X_{it} n'affecte Y_t .

3.2.1.2 Terme de bruit

Comme déjà mentionné, il y a généralement une proportion de la variabilité de la série de sortie non expliquée par les effets dynamiques des séries des entrées sur la sortie. Le bruit (N_t) est donc la différence entre la sortie et la composante dynamique. Il est généralement autocorrélé et pourrait être modélisé, dans le cas stationnaire, par un modèle autorégressif à moyenne mobile (ARMA) :

$$N_t = \frac{\Theta(B)}{\Phi(B)} e_t \quad (3.4)$$

où

$\Phi(B)$ est l'opérateur autorégressif, tel que

$$\Phi(B) = 1 - \phi_1 B - \dots - \phi_p \cdot B^p \quad (3.5)$$

ϕ_j est le paramètre autorégressif au délai j ;

$\Theta(B)$ est l'opérateur de moyenne mobile, tel que

$$\Theta(B) = 1 - \theta_1 \cdot B - \dots - \theta_q \cdot B^q \quad (3.6)$$

θ_j est le paramètre de moyenne mobile au délai j ;

p et q sont respectivement les ordres de l'opérateur de moyenne mobile (au numérateur) et de l'opérateur autorégressif (au dénominateur) du terme du bruit,

e_t est supposé être un bruit blanc de moyenne nulle et de variance σ_e^2 qui suit une distribution normale $N(0, \sigma_e^2)$.

3.2.1.3 Formulation générale

Un modèle de fonction de transfert avec bruit avec une sortie serait formulé :

$$Y_t = \sum_{i=1}^m \frac{(\omega_{i0} - \omega_{i1} \cdot B - \dots - \omega_{is} \cdot B^s)}{(1 - \delta_{i1} \cdot B - \dots - \delta_{ir} \cdot B^r)} B^{b_{\min, i}} X_{it} + \frac{(1 - \theta_1 \cdot B - \dots - \theta_q \cdot B^q)}{(1 - \phi_1 B - \dots - \phi_p \cdot B^p)} e_t \quad (3.7)$$

où m est le nombre de séries d'entrée incorporées dans le modèle de FTB.

La figure 3.2 illustre cette formulation pour le cas d'une seule entrée pour simplifier le schéma. La section suivante présente les hypothèses de base de la modélisation par FTB.




Figure 3. 2 : Représentation d'un modèle de FTB (d'après Hipel et McLeod, 1994)

3.2.2 Hypothèses de base de la modélisation par FTB

La modélisation par FTB repose sur quatre hypothèses principales (Box et Jenkins, 1976; Hipel et McLeod, 1994; Liu *et al.*, 1994) :

- 1- les séries d'entrée peuvent affecter la variable de sortie mais non le contraire (i.e. la relation entre les entrées et la sortie est unidirectionnelle). Si cette hypothèse n'est pas satisfaite, un modèle de FTB n'est pas approprié et devrait être remplacé par un modèle multivarié où les séries d'entrée et de sortie s'affectent mutuellement. La vérification de cette hypothèse se fait à l'aide du calcul de la fonction de corrélation croisée entre la série de sortie et les séries des variables exogènes.

2- les séries d'entrée sont indépendantes du bruit.

Puisque le bruit est défini comme la proportion non expliquée par la composante dynamique, la série N_t est supposée indépendante des séries d'entrées X_{it} . Comme la série N_t est générée par e_t et les séries X_{it} sont générées par les séries d'innovation u_{it} , il s'agit de vérifier si la série des résidus e_t est indépendante des séries u_{it} .

3- le système modélisé est stable.

La stabilité du système signifie qu'un changement infinitésimal fini d'une série d'entrée entraîne un changement infinitésimal fini de la série de sortie. La convergence de la fonction $V_i(B)$ est déterminée par l'opérateur $\Delta_i(B)$. La condition suffisante et nécessaire pour satisfaire la stabilité du système est que les racines de l'équation $\Delta_i(B) = 0$ se situent hors du cercle unitaire. Ceci revient à dire que la somme des poids de la fonction impulsion-réponse est finie.

4- les résidus sont indépendants et identiquement distribués.

Théoriquement, il suffirait de faire l'hypothèse que les résidus e_t sont indépendants et identiquement distribués ($IID(0, \sigma_e^2)$). Pratiquement, l'hypothèse de la normalité des résidus est nécessaire uniquement pour obtenir une estimation efficace des paramètres. En fait, cette hypothèse de la normalité des résidus ne restreint pas la flexibilité des modèles de FTB. Les résidus sont donc supposés indépendants et identiquement distribués suivant une distribution normale ($NID(0, \sigma_e^2)$).

Dans une FTB, les séries d'entrée ne sont pas nécessairement indépendantes. Une série d'entrée peut affecter une autre, tout en influençant la série de sortie. Néanmoins, le choix des séries d'entrée avec le minimum possible d'interaction entre elles faciliterait la tâche d'identification du modèle. En ce qui suit, les étapes de la construction d'un modèle de FTB, i.e. l'identification du modèle, l'estimation de ses paramètres et ensuite sa validation, sont présentées.

3.2.3 Identification du modèle

Elle consiste à identifier les structures de la fonction impulsion-réponse et puis celle du modèle de bruit. Plusieurs méthodologies ont été conçues pour l'identification de la structure de FTB : les méthodes empiriques, la méthode de Box et Jenkins (1976), celle de Haugh et Box (1977), et la méthode de Liu et Hanssens (1982) combinée à la méthode du coin (*Corner method*) développée par Beguin *et al.* (1980).

3.2.3.1 Méthodes empiriques

Les méthodes empiriques consistent à choisir une structure de la fonction impulsion-réponse basée sur la connaissance du phénomène à modéliser (p. ex. Hipel *et al.*, 1982). Pour estimer les paramètres de cette fonction, le terme de bruit est supposé un bruit blanc. Après cette estimation première, les résidus du modèle de FTB sont modélisés par un ARMA et la structure complète de la FTB est spécifiée.

3.2.3.2 Méthode de Box et Jenkins (1976)

Box et Jenkins (1976) ont fourni une procédure pour la modélisation FTB à une seule entrée et une seule sortie. Cette procédure consiste à :

- Trouver le meilleur modèle ARIMA pour la série d'entrée et estimer les innovations u_t de cette série, soit :

$$X_t = \frac{\Theta_x(B)}{\Phi_x(B)} u_t \quad (3.8)$$

- Utiliser le filtre $\left(\frac{\Theta_x(B)}{\Phi_x(B)}\right)^{-1}$ obtenu à la première étape, afin de transformer la série de sortie Y_t en β_t , tel que :

$$\beta_t = \left(\frac{\Theta_x(B)}{\Phi_x(B)}\right)^{-1} Y_t \quad (3.9)$$

- Calculer les poids de la fonction de corrélation croisée (FCC) entre les résidus u_t et β_t . La FCC est définie comme suit :

$$r_{u\beta}(k) = c_{u\beta}(k) / \sqrt{c_u(0) \cdot c_\beta(0)} \quad (3.10)$$

où

$$c_{u\beta}(k) = \begin{cases} n^{-1} \sum_{t=1}^{n-k} u_t \beta_{t+k} & k \geq 0 \\ n^{-1} \sum_{t=1-k}^n u_t \beta_{t+k} & k < 0 \end{cases} \quad (3.11)$$

est la fonction de covariance croisée au délai k de la série des résidus;

n est le nombre d'observations utilisées,

$$c_u(0) = n^{-1} \sum_{t=1}^n u_t^2 \quad (3.12)$$

et

$$c_\beta(0) = n^{-1} \sum_{t=1}^n \beta_t^2 \quad (3.13)$$

sont respectivement les variances de la série u_t et β_t . En fait l'équation 3.10 peut servir à calculer la fonction d'autocorrélation (FAC) des résidus en remplaçant la série β_t par la série u_t .

- Suivre la forme de la FCC et l'occurrence des poids significatifs afin d'identifier les paramètres à incorporer dans la fonction impulsion-réponse ($V(B)$).
- Estimer le terme du bruit par :

$$N_t = (Y_t - \bar{Y}) - V(B)(X_t - \bar{X}) \quad (3.14)$$

et le modéliser, dans le cas stationnaire, par le modèle ARMA le plus approprié.

3.2.3.3 Méthode de Haugh et Box (1977)

Haugh et Box (1977) ont développé une procédure légèrement différente de celle de Box et Jenkins (1976), mais qui est basée aussi sur une procédure de pré-blanchissage. Elle consiste en plusieurs étapes :

- Trouver les meilleurs modèles ARMA pour la série d'entrée et de sortie et obtenir les séries des innovations blanches u_t et v_t .
- Calculer la FCC entre les résidus u_t et v_t avec ses limites de confiance.
- Utiliser les poids significatifs de la FCC (les $r_{uv}(k)$ significatifs aux délais k) pour déterminer les paramètres de la fonction impulsion-réponse aux mêmes délais k :

$$v_k = \sigma_u \sigma_v r_{uv}(k) \quad (3.15)$$

- Identifier le terme du bruit selon la dernière étape de la procédure précédente de Box et Jenkins (1976).

3.2.3.4 Méthode de Liu et Hanssens (1982)

Liu et Hanssens (1982) ont proposé une approche utilisant une méthode qui repose sur les propriétés linéaires de la forme polynomiale de la fonction impulsion-réponse. Leur approche pourrait être considérée comme une généralisation de la régression linéaire multiple. Son avantage est la possibilité de son application directe au cas de la FTB à plusieurs variables exogènes et sortie unique. Elle consiste en trois étapes :

- Supposer la fonction impulsion-réponse entre les variables exogènes et la sortie comme suit :

$$(Y_t - \bar{Y}) = \sum_{i=1}^m (v_{i0} + v_{i1}B + \dots + v_{ik_i}B^{k_i})X_{it} + N_t \quad (3.16)$$

k_i sont choisis suffisamment grands pour incorporer toute la relation dynamique entre les X_{it} et Y_t . N_t est supposé, non comme un bruit blanc dans la méthode

empirique ordinaire, mais plutôt, comme un modèle autorégressif AR(1) dans le cas non saisonnier (Liu *et al.*, 1994) :

$$N_t = \frac{1}{(1 - \phi B)} e_t \quad (3.17)$$

Cette hypothèse concernant N_t offre plusieurs avantages, à savoir :

- elle est bonne si N_t est effectivement un AR(1);
 - elle est une bonne approximation si le bruit est un modèle à moyenne mobile (MA) pur de bas ordre;
 - elle permet d'identifier le besoin d'une différentiation si $\phi \approx 1$;
 - elle permet une représentation du bruit comme un bruit blanc si $\phi \approx 0$.
- Examiner les estimations des paramètres et surtout le paramètre AR(1) comme déjà mentionné. Les résidus sont aussi examinés pour détecter les anomalies du modèle. Le terme de bruit est estimé et modélisé de la même manière que les deux méthodes précédentes.
 - Trouver une forme rationnelle ($V_i(B) = \frac{\Omega_i(B)}{\Delta_i(B)} B^{b_{\min,i}}$) en utilisant la méthode du coin (Beguin *et al.*, 1980; Liu et Hanssens, 1982) afin d'identifier les ordres s_i et r_i de la forme rationnelle de l'opérateur $V_i(B)$ pour chaque entrée X_{it} . Une description détaillée de la méthode du coin se trouve dans Pankratz (1991).

3.2.4 Estimation des paramètres

Après l'identification d'un ou plusieurs modèles possibles de FTB, vient l'étape de l'estimation des paramètres de chacun des modèles avec leurs erreurs d'estimation. En supposant que les résidus de la FTB sont normaux, indépendants et identiquement

distribués, des estimateurs peuvent être obtenus avec la méthode de vraisemblance maximale. Plusieurs algorithmes plus ou moins exacts en présence d'une composante de moyenne mobile ont été développés pour l'estimation des paramètres (Box et Jenkins, 1976; McLeod, 1977; Hillmer et Tiao, 1979; Brockwell et Davis, 1991). Le logiciel SCA, utilisé dans cette recherche, incorpore l'algorithme de Hillmer et Tiao (1979), se servant d'une méthode d'optimisation non linéaire des moindres carrés de type Gauss-Marquardt (MACC, 1965). Si un ou plusieurs paramètres sont statiquement non significatifs, ils devraient être exclus du modèle et par la suite, il faudrait recommencer l'estimation des paramètres.

3.2.5 Validation du modèle

La troisième et dernière étape consiste à valider le modèle pour vérifier si les hypothèses de base de la modélisation par FTB sont respectées. Une fois que la structure complète de la fonction de transfert est identifiée, les résidus du modèle e_t sont calculés comme la différence entre les valeurs observées de la série de sortie et les valeurs prédites à un pas de temps :

$$e_t = Y_t - \hat{Y}_t \quad (3.18)$$

où

$\hat{Y}_t$ sont les prévisions à un pas de temps.

Ces résidus doivent suivre un $NID(0, \sigma_e^2)$, ne montrant aucun patron particulier. Ils doivent être aussi non corrélés avec les innovations des séries d'entrée.

3.2.5.1 Vérification de l'autocorrélation des résidus

Pour vérifier l'indépendance des résidus, l'outil essentiel est l'exploration de la fonction d'autocorrélation (FAC) et la fonction d'autocorrélation partielle (FACP).

Néanmoins, pour arriver au même but, plusieurs formulations du test de Portemanteau ont été développées dont celle de Ljung et Box (1978) :

$$Q_L = n(n+2) \sum_{k=0}^L (n-k)^{-1} r_{ee}^2(k) \quad (3.19)$$

où

Q_L est la statistique du test. Q_L est distribuée selon une loi χ^2 avec $(L-p-q)$ degrés de liberté. Si Q_L dépasse la valeur critique de χ_{L-p-q}^2 au niveau de confiance désiré, les résidus sont considérés autocorrélés.

L est le plus grand délai considéré. Il ne devrait pas dépasser $n/4$;

p et q sont respectivement les ordres des opérateurs AR et MA du modèle de bruit N_t ;

$r_{ee}(k)$ est le coefficient d'autocorrélation d'ordre k de la série des résidus e_t ;

n est le nombre d'observations utilisées dans l'estimation des paramètres.

3.2.5.2 Vérification de l'indépendance entre les variables exogènes et le bruit

Pour tester l'existence de corrélation croisée entre les séries d'entrée et le terme de bruit N_t , l'outil essentiel est l'exploration de la fonction de corrélation croisée (FCC) entre les résidus du modèle de FTB et ceux des innovations des séries d'entrée. Les coefficients de corrélation croisée sont calculés pour des délais k allant de $k \approx -n/4$ à $k \approx n/4$. Une formulation similaire du test de Portemanteau pourrait être utilisée :

$$Q_L = n^2 \sum_{k=0}^L (n-k)^{-1} r_{ue}^2(k) \quad (3.20)$$

où

Q_L est la statistique du test. Elle suit une loi χ^2 avec $(L-r_i-s_i)$ degrés de liberté;

s_i et r_i sont respectivement les ordres des opérateurs du numérateur et dénominateur de l'opérateur $V_i(B)$ associé à l'entrée X_{it} ;

$r_{ue}(k)$ est le coefficient de corrélation croisée d'ordre k entre la série des résidus u_t et e_t ;

Pour tester si $r_{ue}(k)$ possède des valeurs significatives aux délais négatifs, ce qui constituerait une violation de la première hypothèse des FTB, le même test pourrait être formulé comme suit :

$$Q_L = N^2 \sum_{k=-1}^{-L} (N+k)^{-1} r_{ue}^2(k) \quad (3.21)$$

Mais puisque $r_{ue}(-k) = r_{eu}(k)$, la statistique du test s'écrirait alors :

$$Q_L = N^2 \sum_{k=1}^L (N-k)^{-1} r_{eu}^2(k) \quad (3.22)$$

Si Q_L calculée est inférieure à la valeur critique de Q_L au niveau de confiance désiré, on déduit l'absence de corrélation croisée. Si les corrélations croisées sont significatives même si les résidus sont indépendants, ceci est une indication que le modèle de la fonction impulsion-réponse n'est pas approprié. Si les résidus ne sont pas indépendants et les coefficients de corrélation croisée non significatifs, c'est une indication que le terme de bruit est le seul à changer.

3.2.5.3 Test de normalité

En plus d'être indépendants, les résidus e_t devraient suivre une distribution normale avec une variance constante. Il existe plusieurs tests de normalité (p. ex. Kolmogorov-Smirnov; Shapiro-Wilk, (Shapiro et Wilk, 1965); ...) et d'homoscédasticité (p. ex. Hipel *et al.*, 1977)

3.2.6 Prédiction par FTB

Les prévisions par FTB sont produites de façon à ce que l'erreur quadratique soit minimale (*Minimum mean square error forecasts*). Les prévisions à un horizon l , par un modèle formulé selon l'équation 3.8, sont calculées suivant la procédure suivante (Box et Jenkins, 1976; Hipel et McLeod, 1994) :

- éliminer tout d'abord les dénominateurs de l'équation 3.8 et écrire la FTB comme :

$$(\Phi(B)) \cdot \left(\prod_{i=1}^m \Delta_i(B) \right) \cdot ([Y_{t+l}] - \bar{Y}) = (\Phi(B)) \cdot \left(\prod_{i=1}^m \Delta_i(B) \right) \cdot \left(\sum_{i=1}^m \frac{\Omega_i(B)}{\Delta_i(B)} ([X_{t+l}] - \bar{X})_i \right) + \left(\prod_{i=1}^m \Delta_i(B) \right) \cdot (\Theta(B)) \cdot [e_{t+l}] \quad (3.23)$$

Les termes entre crochets $[.]$ réfèrent aux espérances conditionnelles des variables et les $\hat{Y}(j)$, dans le texte qui suit, réfèrent aux prévisions de la série Y .

- isoler le terme Y_{t+l} du côté gauche de l'équation :

$$[Y_{t+l}] = \bar{Y} + \left(1 - (\Phi(B)) \cdot \left(\prod_{i=1}^m \Delta_i(B) \right) \right) \cdot ([Y_{t+l}] - \bar{Y}) + (\Phi(B)) \cdot \left(\prod_{i=1}^m \Delta_i(B) \right) \cdot \left(\sum_{i=1}^m \frac{\Omega_i(B)}{\Delta_i(B)} ([X_{t+l}] - \bar{X})_i \right) + \left(\prod_{i=1}^m \Delta_i(B) \right) \cdot (\Theta(B)) \cdot [e_{t+l}] \quad (3.24)$$

- appliquer les règles suivantes pour obtenir des prévisions à erreur quadratique minimale :

$$\bullet \quad [Y_{t+j}] = \begin{cases} Y_{t+j} & \text{pour } j \leq 0 \\ \hat{Y}(j) & \text{pour } j > 0 \end{cases} \quad (3.25)$$

puisque Y_{t+j} sont des observations connues pour $j \leq 0$ et à déterminer par prévision pour $j > 0$.

$$\bullet \quad [X_{t+j}] = \begin{cases} X_{t+j} & \text{pour } j \leq 0 \\ \hat{X}(j) & \text{pour } j > 0 \end{cases} \quad (3.26)$$

$\hat{X}(j)$ sont déterminés par prévision avec des modèles ARIMA pour les entrées ou connues d'avance comme c'est le cas de cette recherche (cf. section 5.2.4).

$$\bullet \quad [e_{t+j}] = \begin{cases} e_{t+j} & \text{pour } j \leq 0 \\ 0 & \text{pour } j > 0 \end{cases} \quad (3.27)$$

puisque e_{t+j} sont connus pour $j \leq 0$ et leur espérance est égale à zéro pour $j > 0$.

- calculer les variances des prévisions selon la formule :

$$Var(l) = \sum_{i=1}^m \left(\sigma_{u_i}^2 \cdot \sum_{j=0}^{l-1} (v_{ij}^*)^2 \right) + \sigma_e^2 \cdot \sum_{j=0}^{l-1} (\psi_j)^2 \quad (3.28)$$

où

$\sigma_{u_i}^2$ est la variance des résidus du modèle ARMA de la série X_{it} d'entrée (équation 3.9),

σ_e^2 est la variance des résidus du modèle FTB,

v_{ij}^* sont calculés pour la série X_{it} d'entrée par l'équation suivante :

$$\Delta_i(B)\Phi_{X_i}(B)V_i^*(B) = \Omega_i(B)\Theta_{X_i}(B) \quad (3.29)$$

$$\text{et} \quad V_i^*(B) = v_{0i}^* + v_{1i}^* \cdot B + v_{2i}^* \cdot B^2 + \dots \quad (3.30)$$

ψ_j sont calculés par l'équation suivante :

$$\Psi(B) = \frac{\Theta(B)}{\Phi(B)} = 1 + \psi_1 \cdot B + \psi_2 \cdot B^2 + \dots \quad (3.31)$$

Pour la prévision à un pas de temps, avec les valeurs des séries d'entrée connues pour $j=1$, la variance de la prévision est réduite à :

$$Var(1) = \sigma_e^2 \quad (3.32)$$

- calculer les limites de confiance à 95% pour les prévisions $\hat{Y}(1)$, en supposant que les séries u_{it} et e_t sont respectivement $NID(0, \sigma_u^2)$ et $NID(0, \sigma_e^2)$:

$$\hat{Y}(1) \pm 1,96 \sqrt{Var(1)} \quad (3.33)$$

- Si les séries Y_t et X_{it} subissent par une transformation Box-Cox (Box et Cox, 1964), les prévisions qui ont une erreur quadratique moyenne minimale sont celles du domaine transformé. Pour obtenir des prévisions avec la même propriété dans le domaine original (non transformé), il faut que les prévisions subissent une transformation inverse Box-Cox. Si la série de sortie subit une transformation logarithmique, les prévisions dans le domaine non transformé sont calculées comme suit (Granger et Newbold, 1976) :

$$\hat{Y}_{dom_orig}(1) = \exp\left\{\left(\hat{Y}_{dom_trans}(1) + (0,5 \cdot Var_{dom_trans}(1))\right)\right\} \quad (3.34)$$

et la variance des erreurs de la prévision au domaine non transformé est :

$$Var_{dom_orig}(1) = \left\{ \exp(Var_{dom_trans}(1)) - 1 \right\} \cdot \exp\left\{2\hat{Y}_{dom_trans}(1) + (2\hat{Y}_{dom_trans}(1) \cdot Var_{dom_trans}(1))\right\} \quad (3.35)$$

De plus, la limite de confiance supérieure pour la **prévision** (*LPS*) et sa limite inférieure (*LPI*) sont respectivement obtenues par :

$$LPS = \exp\left\{\hat{Y}_{dom_trans}(1) + 1,96 * \sqrt{Var_{dom_trans}(1)} + (0,5 * Var_{dom_trans}(1))\right\} \quad (3.36)$$

$$LPI = \exp\left\{\hat{Y}_{dom_trans}(1) - 1,96 * \sqrt{Var_{dom_trans}(1)} + (0,5 * Var_{dom_trans}(1))\right\} \quad (3.37)$$

3.2.7 Erreur de généralisation

Pour choisir le meilleur modèle parmi un ensemble de modèles possibles, la théorie statistique permet l'utilisation de plusieurs critères (Judge *et al.*, 1985) : l'erreur de prévision finale (EPF) (Akaike 1969, 1970a) et ses versions (Akaike, 1970b; McClave, 1975; Bhansali et Downham, 1977), le critère d'information d'Akaike (CIA) (Akaike 1973, 1974), le critère de Shibata (Shibata, 1976), le critère de Schwarz ou critère d'information bayésien (CIB) (Schwarz, 1978). Ces critères sont formulés de façon à prendre en considération la variance des résidus non expliquée par le modèle avec une pénalité qui augmente proportionnellement au nombre de paramètres estimé par le modèle.

Rao *et al.* (1982) ont appliqué le *CIB* au choix d'un ARMA modélisant des séries de débits annuels. Le *CIB* donne des estimations plus réalistes pour les réseaux de neurones. C'est pourquoi il est choisi pour fins de comparaison. Le *CIB* est formulé comme :

$$CIB = \ln \sigma_e^2 + m_p \cdot (\ln n) / n \quad (3.38)$$

où

m_p est le nombre total de paramètres utilisés par le modèle.

3.3 Réseaux de neurones artificiels (RNA)

3.3.1 Présentation générale et définitions

Les modèles de RNA, présentés dans cette thèse, possèdent quelques aspects innovateurs pertinents pour le domaine de la prévision hydrologique. Aucune des applications publiées dans la littérature n'a utilisé les RNA pour une prévision des débits à un horizon de plus d'un mois, et surtout utilisant une information climatique, telle que les TSO, comme entrées. L'implémentation des RNA dans cette recherche se veut aussi complète que possible d'un point de vue statistique : une méthodologie pour la validation des modèles non linéaires est appliquée aux RNA et une quantification empirique de l'incertitude est effectuée. Aucune des applications publiées des RNA en hydrologie ne va aussi loin. Cette section a pour but de présenter la structure générale des RNA : le modèle du neurone, le perceptron multicouches et sa version récurrente, ainsi que la définition du processus d'apprentissage.

3.3.2 Modèle du neurone

Comme déjà mentionné, McCullogh et Pitts (McCullogh et Pitts, 1943) ont formulé le modèle du neurone. Celui-ci est la cellule élémentaire de calcul dans un RNA. Il consiste en une unité d'addition et une fonction d'activation.

1- **Une unité d'addition** $\sum_{i=1}^m W_{ij} X_i$, qui effectue une somme pondérée des entrées X_i par

les poids des connexions (W_{ij} , $i = 1, m$). W_{ij} est le poids de la connexion qui lie l'entrée X_i au neurone n_j . W_{ij} est positif, si la série X_i doit augmenter la sortie du neurone n_j et W_{ij} est négatif, si X_i doit la diminuer.

2- **Une fonction d'activation** (f_j) qui sert à limiter la sortie du neurone n_j dans un intervalle prédéfini et / ou augmenter la non-linéarité du neurone. Le modèle du

neurone peut inclure une valeur limite dite un **seuil** S (*threshold*). Le terme **seuil** est préféré au terme *biais* couramment utilisé pour éviter toute ambiguïté avec la sens du terme biais en statistique.

$$In_j = \sum_{i=1}^m W_{ij} X_i - S_j \quad (3.39)$$

$$Out_j = f_j(In_j) \quad (3.40)$$

où

In_j est l'entrée de la fonction d'activation du neurone j

Out_j est la sortie de la fonction d'activation du neurone j

X_i est l'entrée i connectée au neurone j

W_{ij} est le poids de la connexion entre l'entrée X_i le neurone j

S_j est le seuil du neurone j

m est le nombre d'entrées connectées au neurone j

f est la fonction d'activation du neurone j

Le schéma d'un neurone est présenté à la figure 3.3.




Figure 3. 3 : Schéma d'un neurone

Il existe au moins trois types de fonction d'activation :

- Les fonctions à seuil (*Hard Limitter*) (figure 3.4a)
centrées autour de 0,5 ,

$$Out_j = \begin{cases} 1 & In_j \geq 0 \\ 0 & In_j < 0 \end{cases} \quad (3.41)$$

ou centrées autour de 0,

$$Out_j = \begin{cases} 1 & In_j > 0 \\ 0 & In_j = 0 \\ -1 & In_j < 0 \end{cases} \quad (3.42)$$

- Les fonctions linéaires à seuil (figure 3.4b)

centrées autour de 0,5 ,

$$Out_j = \begin{cases} 1 & In_j \geq 1 \\ In_j & -0 < In_j < 1 \\ 0 & In_j \leq 0 \end{cases} \quad (3.43)$$

ou centrées autour de 0,

$$Out_j = \begin{cases} 1 & In_j \geq 0,5 \\ In_j + 0,5 & -0,5 < In_j < 0,5 \\ 0 & In_j \leq -0,5 \end{cases} \quad (3.44)$$

- Les fonctions sigmoïdes qui peuvent avoir une forme logistique ou une forme hyperbolique (figure 3.4c). L'équation générale des fonctions sigmoïdes est :

$$Out_j = c_n \frac{\exp(k_n \cdot In_j) - 1}{\exp(k_n \cdot In_j) + 1} + r_n; \quad c_n, k_n, r_n \in Re; \quad c_n, k_n > 0 \quad (3.45)$$

La forme logistique :

$$Out_j = f(In_j) = \frac{1}{1 + \exp(-In_j)} \quad (3.46)$$

avec un ensemble d'arrivée de 0 à 1.

La forme tangente hyperbolique :

$$Out_j = f(In_j) = th(In_j) = \frac{\exp(In_j) - \exp(-In_j)}{\exp(In_j) + \exp(-In_j)} \quad (3.47)$$

avec un ensemble d'arrivée de -1 à 1.




Figure 3. 4 : Fonctions d'activation de neurone (a) à seuil, (b) linéaires à seuil, (c) sigmoïdes : logistique et tangente hyperbolique

3.3.3 Perceptron multicouches

Le perceptron multicouches, qui est le réseau de neurone le plus populaire, est formé de trois groupes de neurones (figure 3.5) :

- groupe primaire (ou groupe d'entrées) constitué de neurones qui recueillent les entrées;
- groupe intermédiaire ou *couches cachées* (une ou plusieurs) qui transforment et propagent l'information à travers le réseau; et
- groupe de sortie qui contient les neurones qui produisent les résultats.

Pour éviter toute ambiguïté en parlant du nombre de couches dans ce document, les RNA sont identifiés par leur nombre de couches cachées.

L'équation générale d'un RNA de type perceptron multicouches, avec une seule couche cachée et une sortie scalaire, est écrite comme suit :

$$\hat{Y}_t = f_o \left[\sum_{j=1}^{HU} WO_j * f_h \left(\sum_{i=1}^m WH_{ij} \cdot X_{it} + S_j \right) + S_o \right] \quad (3.48)$$

où

WH_{ij} est le poids de la connexion entre la $i^{ième}$ entrée et le $j^{ième}$ neurone sur la couche cachée

WO_j est le poids de la connexion entre le $j^{ième}$ neurone sur la couche cachée et le neurone de sortie

f_h est la fonction d'activation du neurone de la couche cachée,

f_o est la fonction d'activation du neurone de la sortie

S_j est le seuil de la fonction d'activation du $j^{ième}$ neurone sur la couche cachée

S_o est le seuil de la fonction d'activation du neurone de sortie

HU est le nombre de neurones sur la couche cachée.




Figure 3.5 : Réseau de neurones artificiels de type perceptron multicouches avec une seule couche cachée et une sortie

Trois types d'entrée pourraient être introduits dans le RNA de l'équation 3.48 afin de prédire une sortie quelconque : des variables exogènes, des composantes de délai de la série de sortie (i.e. des valeurs de la série de sortie antérieures à la valeur à prédire), et des erreurs des sorties du RNA pour les pas de temps antérieurs. Si les deux premiers types sont utilisés seuls, le RNA est de type *autorégressif neuronal avec variables exogènes* ou *NNARX* (équation 3.49); si les erreurs antérieures sont introduites, le RNA est dit de type *autorégressif neuronal à moyenne mobile avec variables exogènes* ou *NNARMAX* (équation 3.50). Ce dernier est dit *réseau de neurones récurrent* parce qu'il renferme une boucle : la sortie du RNA dépend, non seulement des entrées actuelles, mais aussi des erreurs des sorties antérieures (figure 3.6).

$$\hat{Y}_t = f_o \left[\sum_{j=1}^{HU} WO_j * f_h \left(\sum_{i=1}^m WH_{ij} \cdot X_{it} + \sum_{k=1}^p WH_{kj} \cdot Y_{t-k} + S_j \right) + S_o \right] \quad (3.49)$$

$$\hat{Y}_t = f_o \left[\sum_{j=1}^{HU} WO_j * f_h \left(\sum_{i=1}^m WH_{ij} \cdot X_{it} + \sum_{k=1}^p WH_{kj} \cdot Y_{t-k} + \sum_{l=1}^q WH_{lj} \cdot e_{t-l} + S_j \right) + S_o \right] \quad (3.50)$$

où

e_{t-l} est la valeur de l'erreur du RNA, l pas en arrière, calculée comme :

$$e_{t-l} = Y_{t-l} - \hat{Y}_{t-l} \quad (3.51)$$

p et q sont respectivement le nombre de composantes de délai de la série de sortie et le nombre d'erreurs antérieures à incorporer comme entrées. Par analogie aux méthodes de Box et Jenkins (1976), p et q sont appelés respectivement les ordres du terme autorégressif et de celui à moyenne mobile.




Figure 3. 6 : Réseau de neurones artificiels de type NNARMAX avec une seule couche cachée, une sortie et une boucle de moyenne mobile

Sans sous-estimer toute l'analogie cognitive à l'origine du développement des RNA, le perceptron multicouches, décrit par l'équation 3.49, appartient à la classe des modèles statistiques non linéaires de régression et de discrimination. Dans le cadre des outils statistiques, les réseaux de neurones pourraient être considérés comme étant une "technique d'inférence (de généralisation) non linéaire, nonparamétrique, entièrement indépendante du modèle" (Azoff, 1994). L'application de la statistique aux RNA est détaillée dans Cheng et Titterington (1994), Ripley (1994), Bishop (1995) et Ripley (1996).

L'apprentissage d'un RNA est l'estimation de l'ensemble de ses paramètres (θ_{RNA}) (ses poids WH , WO et ses seuils S). Cette estimation se fait par minimisation d'une *fonction objectif* (terme plus général que *fonction d'erreur*) de type :

$$F_{OBJ}(\theta_{RNA}) = \frac{1}{2n} \sum_{i=1}^n (Y_i - \hat{Y}_i | \theta_{RNA})^T (Y_i - \hat{Y}_i | \theta_{RNA}) \quad (3.52)$$

afin de trouver les paramètres $\hat{\theta}_{RNA}$, tels que

$$\hat{\theta}_{RNA} = \arg_{\theta_{RNA}} \min F_{OBJ}(\theta_{RNA}) \quad (3.53)$$

à l'aide d'une procédure itérative

$$\theta_{RNA}(it+1) = \theta_{RNA}(it) + \Delta\theta_{RNA}(it) \quad (3.54)$$

où

$(.)^T$ est la transposée de la matrice $(.)$

it est le nombre d'itérations effectuées

$\Delta\theta_{RNA}(it)$ est la correction apportée à θ_{RNA} à l'itération it .

3.3.4 Propriétés des réseaux de neurones

Si les applications des réseaux de neurones sont très avancées comme le montrent les exemples cités précédemment (cf. section 2.7.4), les questions mathématiques sont encore plus nombreuses que les réponses. Comme le montre l'exposé qui suit, les hypothèses de base requises pour la modélisation par RNA ne font pas l'unanimité des théoriciens. On manque aussi de cadre d'implémentation des réseaux de neurones artificiels. Il s'agit donc plus de *propriétés* que d'hypothèses de bases rigoureuses. Les RNA possèdent les propriétés suivantes (d'après Mangeas, 1997 ; Haykin, 1999) :

3.3.4.1 Non-linéarité

Étant donné que le neurone est un élément non linéaire et que les neurones sont parallèlement distribués dans le réseau, celui-ci peut s'adapter aux phénomènes physiques complexes, là où le mécanisme responsable de la génération du signal d'entrée et/ou les relations entre les entrées et les sorties sont non linéaires. Mais cette non-linéarité ne dépend pas uniquement de la fonction d'activation, mais aussi de la norme des poids. Plus cette norme est petite, plus les entrées (In) parvenant aux neurones se situent au voisinage de zéro et plus les fonctions sigmoïdes utilisées sont proches des fonctions linéaires (cf. figure 3.4c).

3.3.4.2 Tolérance au manque d'information

Vu que la distribution de l'information est parallèle, l'endommagement d'un neurone ou d'une connexion ou bien la perte de données ne provoquent pas un échec irrémédiable dans la performance du réseau, mais seulement une dégradation moins sérieuse dans les résultats. Ceci est seulement vrai si la couche cachée est munie de suffisamment de neurones. Le calcul de la sortie étant mené par plusieurs neurones, il y a différents chemins de l'entrée à la sortie.

3.3.4.3 Résistance aux entrées aberrantes

Du fait des filtres saturants que constituent les fonctions d'activation sigmoïdes, le réseau est résistant aux valeurs aberrantes. Néanmoins, un réseau de neurones est prisonnier des données qui ont servi à sa calibration. Si ces données ne sont pas réparties sur tout le continuum de leur variabilité, le réseau sera incapable d'extrapoler sur les données. Par contre, pour un modèle linéaire, il suffit que les exemples pour l'estimation des paramètres se situent sur les extrémités de ce continuum.

3.3.4.4 Possibilité de se passer de **prérequis**

Le réseau de neurones est - en principe - capable de faire correspondre à un ensemble de sorties, un ensemble donné d'entrées, sans avoir recours pour cette opération à une distribution de probabilité des variables du modèle ou à un prérequis des relations entre elles (Haykin, 1999). Cette notion, bien que présente dans plusieurs références de base sur les RNA, n'est pas partagée par les statisticiens qui ont étudié les RNA. En fait, Bishop (1995) démontre que les RNA requièrent les mêmes hypothèses de distribution que les autres modèles statistiques pour obtenir des estimations efficaces et optimales.

D'autre part, toute connaissance du phénomène modélisé est utile pour déterminer la structure du réseau, analyser les résultats, choisir la fonction de transfert et déterminer les critères de l'erreur que le réseau doit satisfaire.

3.3.4.5 **Non-unicité** du modèle par rapport aux paramètres

On peut trouver deux ensembles de poids différents qui génèrent la même sortie. De même, un même ensemble d'entrées et de sorties peut aboutir à des ensembles de paramètres très différents à chaque fois que le RNA est entraîné. Les performances de ces différents modèles peuvent cependant être identiques.

3.3.4.6 **Adaptabilité**

Les réseaux de neurones pourraient être conçus de manière à changer les poids de leurs synapses en temps réel, en fonction des changements de l'environnement. Ils peuvent donc opérer dans un environnement non stationnaire, i.e. dont les propriétés statistiques sont fonction du temps.

3.3.4.7 Utilisation des données à leur état brut

Le réseau de neurones - en principe - traite avec les données telles qu'elles sont, sans transformation pour rendre leur série homogène ou stationnaire ou pour changer leur échelle. Néanmoins, il est préférable de standardiser les entrées et les sorties (i.e. soustraire une mesure de localisation, telle que la moyenne, et diviser la différence par une mesure de la dispersion, telle que l'écart type). Cette transformation permet de mieux éviter les minima locaux et d'avoir, pour une valeur d'initialisation des poids et seuils proches de zéro, une valeur plus proche du minimum global. Ceci est d'autant plus vrai pour les méthodes d'apprentissage de type gradient de la plus forte pente (*steepest descent gradient*), telles que la rétropropagation, qui sont très sensibles aux valeurs initiales.

3.3.4.8 Autres propriétés

Haykin (1999) fait allusion à d'autres avantages des réseaux de neurones, dont:

- * **Universalité** des analyses et des conceptions: possibilité de partager les théories, les types de neurones, les algorithmes d'apprentissages, ...etc., dans différentes applications des réseaux de neurones.
- * **Analogie avec la neurobiologie**: la science neurologique inspire le développement d'autres réseaux artificiels qui sont, à leur tour, des outils de recherche pour interpréter les phénomènes neurobiologiques.

Les sections 3.3.3 à 3.3.5 décrivent les étapes de la construction d'un RNA. Celles-ci, par analogie aux étapes de la méthodologie de Box et Jenkins (1976), sont nommées : identification du RNA, estimation de ses paramètres et validation du modèle.

3.3.5 Identification d'un RNA

Comme déjà mentionné, il n'y a pas de méthodologie bien précise et rigoureuse pour développer un RNA capable de résoudre un problème donné. On va vers ce but par essais et erreurs, voire par tâtonnements. Ceci est dû à la flexibilité inhérente au RNA, à son caractère foncièrement non linéaire et à la difficulté de déterminer la signification statistique des paramètres estimés, tellement l'information est cachée dans la structure parallèle du RNA. L'identification d'un RNA de type NNARX ou NNARMAX consiste en une série de choix de la part de l'utilisateur.

3.3.5.1 Choix des entrées du RNA

Ce choix devrait tenir compte des autocorrélations pour déterminer les composantes de délai de la série de sortie, des corrélations croisées et de l'analyse de causalité pour déterminer les variables exogènes à incorporer. Il tient aussi compte de la disponibilité des données, des facteurs déterministes ou de toute information connue *a priori* (Lachtermacher et Fuller, 1994; Dimopoulos *et al.*, 1996). Il est à noter que tous ces outils appartiennent plus aux modèles linéaires. Par conséquent, ils servent juste à suggérer une première tentative de RNA.

3.3.5.2 Choix du modèle de neurone

Ce choix comprend aussi celui de la fonction d'activation. Celle-ci est essentielle pour introduire la non-linéarité dans le RNA. Sans la non-linéarité, les RNA ne sont pas plus puissants qu'un modèle linéaire généralisé, parce que la combinaison de fonctions linéaires demeure une fonction linéaire. Mais s'il est connu, par les lois physiques par exemple, que le système à modéliser est linéaire, il est possible d'imposer des contraintes aux RNA pour forcer les paramètres à utiliser la portion presque linéaire

de la fonction d'activation sigmoïde. L'extrapolation est plus fiable avec les modèles linéaires qu'avec les modèles non linéaires flexibles, même si elle n'est pas aussi fiable que l'interpolation.

3.3.5.3 Choix de la structure du modèle

La structure d'un RNA est déterminée par le nombre de couches cachées, l'existence de connexions entre les neurones (un RNA peut aussi être partiellement connecté) et le nombre de neurones sur les couches cachées. Elle doit être aussi adéquate tant pour l'ensemble de données qui a servi à l'apprentissage du RNA que pour d'autres données (ensemble de test). Il est à noter que la complexité du modèle de RNA dépend aussi bien du nombre de poids et de seuils que de leurs normes (Vapnik, 1992). Les nombres de neurones et de couches jouent uniquement sur le premier facteur.

Dans la plus part des problèmes de prévisions, une seule couche cachée est suffisante, car un RNA à une couche cachée est un approximateur universel capable de modéliser n'importe quelle fonction continue dans R^e à n'importe quelle précision (Hornik *et al.*, 1989). Mais, cette propriété ne garantit pas qu'un RNA saura modéliser une fonction quelconque avec un nombre *raisonnable* de neurones, ni qu'il sera possible de déterminer ce nombre pour un problème en question (Fortin *et al.*, 1997). La question de la structure du RNA est loin d'être résolue. La réponse la plus difficile à déterminer est le nombre de neurones *minimal et adéquat*.

Un réseau incapable de modéliser la complexité d'un système, que cela soit faute de neurones sur la couche cachée ou de temps suffisant d'apprentissage, est dit qu'il souffre de *sous-apprentissage (underfitting)*. Un réseau qui performe bien sur son ensemble d'apprentissage, mais qui performe beaucoup moins bien sur d'autres données, que cela soit dû à trop de neurones sur la couche cachée ou à un apprentissage excessif,

est dit qu'il souffre de *surapprentissage* (*overfitting*). Évalué sur un ensemble test, un RNA insuffisamment complexe produit des sorties avec un biais excessif. Un RNA qui a surappris fait une mauvaise évaluation de la variance de la perturbation aléatoire associée au phénomène modélisé, et par conséquent, produit des sorties avec une variance excessive (Geman *et al.*, 1992). Le choix de la structure du RNA est donc un compromis entre le sous-apprentissage et le surapprentissage. Le surapprentissage est spécialement dangereux, car il pourrait produire des sorties qui dépassent largement l'ordre de grandeur des variables (White, 1992).

Il existe plusieurs règles heuristiques pour suggérer *à priori* un nombre de neurones sur la couche cachée en fonction du nombre d'observations utilisées dans l'apprentissage et le nombre d'entrées du modèle (p. ex. Weigend *et al.*, 1990; Minns et Hall, 1996; ...). Plus le nombre de paramètres dans le RNA augmente par rapport au nombre d'observations, plus le surapprentissage amplifie le bruit dans les sorties du RNA (Moody, 1992).

Cependant, ces règles heuristiques dépendent de la nature des données utilisées et du bruit qui y est présent. Elles ne sont donc pas à généraliser (Sarle, 1999). Il faut procéder par essais et erreurs. Plusieurs méthodes pour déterminer le nombre de neurones dans la couche cachée d'un RNA sont disponibles afin d'obtenir un modèle avec une bonne capacité de généralisation. Quelques-unes de ces méthodes sont présentées à la section 3.3.7.2.

3.3.6 Estimation des paramètres (apprentissage) du RNA

L'estimation des paramètres comporte plusieurs choix : le critère d'erreur à atteindre, l'algorithme d'optimisation de ce critère, les paramètres de l'algorithme et la

gamme des valeurs initiales aléatoires des poids et seuils. Dans la modélisation par RNA, certains choix ont été faits pour ce travail :

- Un des objectifs de cette recherche étant de comparer les FTB et les RNA, un même critère d'erreur est choisi pour les deux méthodes, soit l'erreur quadratique moyenne.
- Il est recommandé d'initialiser le RNA avec des valeurs de paramètres proches de zéro pour éviter d'obtenir des matrices mal conditionnées (Sarle, 1999).
- Le RNA devrait être entraîné en commençant par plusieurs valeurs initiales différentes pour éviter les minima locaux.

Il existe plusieurs algorithmes pour estimer les paramètres d'un RNA. Le plus populaire de ceux-ci est la *rétropropagation du gradient de l'erreur*. Celui-ci, comme son nom l'indique, est un algorithme qui ajuste les poids et seuils du RNA en utilisant les dérivées premières de la fonction objectif (d'où *gradient*) et propage l'ajustement des neurones de sortie vers ceux de la première couche cachée (d'où *rétropropagation*). La rétropropagation est surtout adaptée aux fonctions d'activation dérivables avec des patrons d'entraînement abondants (Lippmann, 1987).

La rétropropagation, comparée aux autres méthodes d'optimisation de la fonction objectif décrites ci-dessous, souffre spécialement de la lenteur de la convergence de la méthode et de la difficulté à déterminer le taux d'apprentissage. Pour remédier à la première lacune, il existe deux variantes de la rétropropagation : la Quickprop (Fahlman, 1989) et la rétropropagation résiliente (Riedmiller et Braun, 1993). Les méthodes d'optimisation non linéaires connues dans la littérature de recherche opérationnelle et d'analyse numérique depuis de nombreuses années peuvent aussi être utilisées pour entraîner un RNA. De plus, elles sont plus efficaces et plus capables d'éviter les minima locaux.

Ces méthodes d'optimisation non linéaires se servent soit du calcul du *gradient conjugué* (à celui de la plus forte pente) ou bien du deuxième ordre de l'expansion de Taylor de la fonction objectif (méthodes newtoniennes ou quasi newtoniennes).

$$F_{OBJ}(\theta_{RNA} + \Delta\theta_{RNA}) = F_{OBJ}(\theta_{RNA}) + (\Delta\theta_{RNA})^T \cdot \nabla F_{OBJ}(\theta_{RNA}) + \frac{1}{2}(\Delta\theta_{RNA})^T H(\Delta\theta_{RNA}) + O(\|\Delta\theta_{RNA}\|^2) \quad (3.55)$$

où H est la matrice hessienne (celle des dérivées secondes).

La différence entre les méthodes newtoniennes et quasi newtoniennes est dans l'approximation de H . Mais elles ont besoin de beaucoup de temps de calcul sur ordinateur (Demuth et Beale, 1998, p.36 du chapitre 5). La méthode de Levenberg-Marquardt (Marquardt, 1963) est une méthode intermédiaire entre le gradient de la plus forte pente et les méthodes quasi newtoniennes. Elle est actuellement la méthode standard tant que la fonction objectif est une somme d'erreurs quadratiques ; ce qui est le cas typique dans les RNA (Mangeas, 1997). Elle est basée sur une approximation de la matrice hessienne comme

$$H = J^T J \quad (3.56)$$

où J est la matrice jacobienne (des dérivées premières), qui est calculée par rétropropagation.

Les algorithmes du gradient conjugué, des méthodes quasi newtoniennes et de Levenberg-Marquardt fonctionnent mieux que l'algorithme classique de rétropropagation (Bertsekas et Tsitsiklis, 1996).

3.3.7 Limites et précautions dans la modélisation par RNA

Deux questions majeures doivent être résolues dans la modélisation par RNA : comment être le plus proche possible du minimum global et comment obtenir un RNA

performant bien sur des données qui n'appartiennent pas à son ensemble d'apprentissage.

3.3.7.1 Problème des minima locaux

Pendant la minimisation de la fonction objectif, les poids et seuils peuvent converger vers des valeurs qui représentent des minima locaux de la fonction objectif et non un minimum global. De fait, avec la complexité de la surface de la fonction objectif, il est quasiment impossible d'atteindre le minimum global. Il faut pourtant en être le plus proche. Pour éviter les minima locaux, il est conseillé de (Chitra, 1993) :

- * Réinitialiser plusieurs fois les poids et recommencer l'apprentissage.
- * Augmenter légèrement les poids pour sortir du voisinage du minimum local et recommencer l'optimisation.
- * Utiliser les techniques plus complexes d'optimisation stochastique globale, comme le *recuit simulé* (*simulated annealing*, cf. Aarts et Korst, 1989; Reeves, 1993; et Masters, 1995).

3.3.7.2 Problème de généralisation

La modélisation par RNA consiste, comme déjà cité, à trouver la juste mesure entre le sous-apprentissage et le surapprentissage. La complexité du RNA dépend aussi bien de la dimension de la matrice des paramètres que des normes de ceux-ci (Vapnik, 1992). Le problème de sous-apprentissage est facile à résoudre en augmentant la taille du réseau. Plusieurs méthodes ont tenté de résoudre le problème de surapprentissage, voire l'automatiser. Dans le texte qui suit, trois méthodes sont présentées : l'élagage, l'arrêt prématuré et la régularisation.

a) Élagage

Une première méthode est de commencer avec un réseau complexe, et de supprimer les neurones avec des poids de connexions négligeables. Cette méthode s'appelle l'élagage (*pruning*). L'élagage est une méthode d'élimination par pas (*stepwise*) descendants qui tend à éliminer les poids d'un RNA entièrement connecté. Il pourrait être fait selon deux méthodes, celle du dommage optimal du cerveau (*optimal brain damage*, Le Cun *et al.*, 1989) ou celle du chirurgien optimal du cerveau (*optimal brain surgeon*, Hassibi et Stork, 1993; et Hansen et Pedersen, 1994). La première méthode est basée sur le calcul de la matrice de dérivées secondes de la fonction objectif en fonction des paramètres, tandis que la seconde est basée sur le calcul de l'augmentation minimale de la fonction objectif due à l'élimination d'un poids. Le réseau allégé est ré-entraîné et sa capacité de généralisation est testée à chaque élimination. Le RNA obtenu par élagage, et qui minimise l'erreur de généralisation (cf. section 3.37), est choisi. Une telle procédure joue sur la dimension de la matrice des paramètres. Elle est coûteuse du point de vue temps et durant la procédure de l'élimination des poids, on pourrait tomber sur des RNA instables. Une méthode inverse est aussi connue. Il s'agit de commencer par un réseau simple et le rendre plus complexe en ajoutant des neurones sur la couche cachée. Le RNA retenu est celui qui minimise l'erreur de généralisation.

b) Arrêt prématuré

Une deuxième méthode, appelée l'arrêt prématuré (*early stopping*, p. ex. Weigend, 1994), consiste à utiliser beaucoup de neurones sur la couche cachée pour éviter les minima locaux et en même temps limiter le temps d'apprentissage. L'arrêt prématuré joue indirectement sur le nombre effectif de paramètres. Il est basé sur le concept statistique de la division d'échantillon (*split-sampling*). Les données sont divisées en trois ensembles : celui de l'apprentissage, celui de la validation (pour arrêter

l'apprentissage) et celui du test (pour tester la généralisation du RNA). L'algorithme d'apprentissage RNA est arrêté, avant qu'il atteigne le minimum, lorsque le critère d'erreur, mesuré sur l'ensemble de validation, commence à augmenter de façon constante. Notons que cette méthode produit un modèle qui est biaisé vers l'ensemble de validation. La méthode est aussi critiquée car ni l'ensemble d'apprentissage ni celui de validation n'utilise l'échantillon au complet.

c) Régularisation

Une troisième méthode, dites méthode de régularisation (*weight decay*, p. ex. Weigend *et al.*, 1991), joue sur les normes de la matrice des paramètres. Elle consiste à introduire un terme de pénalité dans la fonction objectif utilisée, afin de restreindre progressivement l'espace du vecteur des paramètres dans un voisinage de zéro. La fonction objectif s'écrit alors :

$$F_{OBJ}(\theta_{RNA}) = \frac{1}{2n} \sum_{i=1}^n (Y_i - \hat{Y}_i | \theta_{RNA})^T (Y_i - \hat{Y}_i | \theta_{RNA}) + \frac{1}{2n} (\theta_{RNA})^T (\alpha_p I) (\theta_{RNA}) \quad (3.57)$$

où α_p est un coefficient pondérant les termes de régularisation et I est la matrice identité. Plus α_p est grand, plus on considère qu'il est important d'avoir un modèle de faible complexité. Cette méthode fait l'hypothèse implicite que la distribution des vrais paramètres est gaussienne et centrée autour de zéro. McKay (p. ex. McKay, 1992a et 1992b) et Neal (1996) élaborent un cadre statistique basé sur la théorie bayésienne pour déterminer le coefficient de régularisation.

Les trois méthodes citées ci-dessus jouent sur les facteurs de temps d'apprentissage, de la dimension et de la norme de la matrice des paramètres. Cependant, le sur-

apprentissage peut être dû à un mauvais choix de l'ensemble d'apprentissage. Un ensemble avec peu de bruit, beaucoup de redondance ou qui ne reflète pas toute la variabilité de la population des variables d'entrée, entraînerait une mauvaise performance du RNA sur des données hors de son ensemble d'apprentissage.

3.3.8 Validation d'un modèle de RNA

La modélisation par RNA manque d'outils de validation comme celles des modèles de Box et Jenkins. Idéalement, les résidus du modèle devraient être imprévisibles quelle que soit la combinaison des entrées et des sorties antérieures du modèle. La première validation est l'inspection des graphiques de la FCC entre les séries de variables exogènes et les résidus du modèle et la FAC des résidus du modèle. Ces outils qui appartiennent aux modèles linéaires de Box et Jenkins (1976) sont insuffisants, parce que les relations entre les entrées et les sorties, dans les RNA, peuvent prendre n'importe quelle forme. Bien qu'une vérification complète de l'indépendance soit irréalisable, Billings et Zhu (1994) proposent de vérifier si les poids de six fonctions de corrélation croisée à des ordres plus élevés sont significatifs. Ces FCC ont été proposées comme méthode de validation pour les RNA par Nørgaard (1997). Dans l'implémentation de ces méthodes de validation faites dans ce travail de recherche, les poids des FCC sont calculés jusqu'au délai $|k|=n/4$, suivant les suggestions de Box et Jenkins (1976) et Hipel et McLeod (1994).

$$r_{e^2, e^2}(k) = \frac{\sum_{t=1}^{n-k} (e^2(t) - \bar{e^2}) \cdot (e^2(t-k) - \bar{e^2})}{\sqrt{\sum_{t=1}^n (e^2(t) - \bar{e^2})^2} \cdot \sqrt{\sum_{t=1}^n (e^2(t) - \bar{e^2})^2}} = \begin{cases} 1 & k=0 \\ 0 & \forall |k| \leq n/4, \text{ et } k \neq 0 \end{cases} \quad (3.58)$$

$$r_{X_i, e}(k) = \frac{\sum_{t=1}^{n-k} (X_i(t) - \bar{X}_i) \cdot (e(t-k) - \bar{e})}{\sqrt{\sum_{t=1}^n (X_i(t) - \bar{X}_i)^2} \cdot \sqrt{\sum_{t=1}^n (e(t) - \bar{e})^2}} = 0, \quad \forall |k| \leq n/4 \quad (3.59)$$

$$r_{X_i^2, e^2}(k) = \frac{\sum_{t=1}^{n-k} (X_i^2(t) - \overline{X_i^2}) \cdot (e^2(t-k) - \overline{e^2})}{\sqrt{\sum_{t=1}^n (X_i^2(t) - \overline{X_i^2})^2} \cdot \sqrt{\sum_{t=1}^n (e^2(t) - \overline{e^2})^2}} = 0, \quad \forall |k| \leq n/4 \quad (3.60)$$

$$r_{X_i^2, e}(k) = \frac{\sum_{t=1}^{n-k} (X_i^2(t) - \overline{X_i^2}) \cdot (e(t-k) - \overline{e})}{\sqrt{\sum_{t=1}^n (X_i^2(t) - \overline{X_i^2})^2} \cdot \sqrt{\sum_{t=1}^n (e(t) - \overline{e})^2}} = 0, \quad \forall |k| \leq n/4 \quad (3.61)$$

$$r_{\alpha, e^2}(k) = \frac{\sum_{t=1}^{n-k} (\alpha(t) - \overline{\alpha}) \cdot (e^2(t-k) - \overline{e^2})}{\sqrt{\sum_{t=1}^n (\alpha(t) - \overline{\alpha})^2} \cdot \sqrt{\sum_{t=1}^n (e^2(t) - \overline{e^2})^2}} = \begin{cases} k_2 & k=0 \\ 0 & \forall |k| \leq n/4 \end{cases} \quad (3.62)$$

$$r_{\alpha, X_i}(k) = \frac{\sum_{t=1}^{n-k} (\alpha(t) - \overline{\alpha}) \cdot (X_i^2(t-k) - \overline{X_i^2})}{\sqrt{\sum_{t=1}^n (\alpha(t) - \overline{\alpha})^2} \cdot \sqrt{\sum_{t=1}^n (X_i^2(t) - \overline{X_i^2})^2}} = 0, \quad \forall |k| \leq n/4 \quad (3.63)$$

où

$$\alpha_i(t) = Y(t) \cdot e(t) \quad (3.64)$$

et

$$k_2 = \frac{\sqrt{\sum_{t=1}^n (e^2(t) - \overline{e^2})^2}}{\sqrt{\sum_{t=1}^n (\alpha(t) - \overline{\alpha})^2}} \quad (3.65)$$

Il est aussi intéressant d'examiner l'histogramme des résidus et vérifier par des tests, comme mentionné à la section 3.2.5, l'hypothèse de la distribution normale des résidus. La vérification ultime reste bien sûr la performance du modèle en prévision.

3.3.9 Estimation de l'erreur de généralisation

L'erreur de généralisation est une inférence statistique sur la performance d'un modèle sur un échantillon qui n'a pas été utilisé pour l'estimation des paramètres de ce modèle. Les méthodes pour estimer cette erreur peuvent être groupées sous deux grandes catégories : les méthodes basées sur des statistiques calculées à partir de l'échantillon d'estimation des paramètres et celles basées sur les techniques de ré-échantillonnage.

Comme déjà cité à la section 3.2.7, la théorie statistique offre, pour le cas des modèles linéaires, plusieurs statistiques de la première catégorie. Celles-ci peuvent être utilisées comme des estimations approximatives de l'erreur de généralisation d'un modèle neuronal à condition d'avoir un "grand" nombre de cas pour l'apprentissage. En fait, le critère d'information bayésien (CIB) a été mentionné comme étant un meilleur estimateur de l'erreur de généralisation des RNA (Sarle, 1995 ; Mangeas, 1997). Le critère d'information d'Akaike et l'erreur de prévision finale tendent à sous-estimer cette erreur (Sarle, 1995).

La validation croisée (*cross-validation*) et les techniques de *bootstrap* (Efron, 1979) font partie des techniques de ré-échantillonnage utilisées pour l'estimation de l'erreur de généralisation des RNA. Elles sont jugées meilleures que les statistiques à partir d'un seul échantillon (Efron et Tibshirani, 1993 ; Tibshirani, 1996). Une brève description est donnée dans le texte qui suit.

3.3.9.1 Validation croisée

La validation croisée d'ordre k consiste à diviser l'échantillon utilisé pour l'apprentissage du RNA en k sous-échantillons de tailles presque égales. Le RNA est entraîné laissant de côté un des sous-échantillons. Le critère d'erreur choisi est calculé sur le sous-échantillon abandonné. La procédure est répétée pour les k échantillons et l'erreur de généralisation est la moyenne des erreurs calculées. Si $k=n$ (le nombre de cas utilisé pour l'apprentissage), le RNA est entraîné n fois. Cette variante est appelée

validation croisée laissant une observation de côté (leave-1-out cross-validation). Cette technique donne des estimations raisonnables pour les fonctions d'erreur continues, comme l'erreur quadratique moyenne (Efron et Tibshirani, 1993).

Une distinction est nécessaire entre la technique de validation croisée et celle de la division d'échantillon utilisée dans la méthode d'arrêt prématuré. Dans la division d'échantillon, un seul sous-ensemble (celui de la validation) est consacré à l'estimation de l'erreur ; il n'y a donc pas de validation *croisée*. La validation croisée, proprement dite, est nettement supérieure aux méthodes basées sur la division d'échantillon, avec les échantillons limités (Goutte, 1997).

3.3.9.2 Technique de bootstrap

Le bootstrap consiste à former de 200 à 2000 échantillons aléatoires de taille n par tirage avec remise à partir de l'échantillon original (Efron, 1979). Ces échantillons sont utilisés pour calculer une statistique d'intérêt, pour ré-entraîner un RNA et estimer l'erreur moyenne des sorties des RNA obtenus, ... etc. Le bootstrap peut être utilisé sans connaître la distribution de probabilité du bruit et il tient compte de la variabilité due aux valeurs initiales des poids et seuils et à l'occurrence de minima locaux. Il est cependant très coûteux en ce qui concerne le temps de calcul (Baxt et White, 1995 ; Tibshirani, 1996 ; Heskes, 1997).

Un des meilleurs estimateurs par bootstrap est l'estimateur $0,632$ ($err_{0,632}$, Efron et Tibshirani, 1993, pp. 252-255). Il fonctionne bien pour de petits échantillons. Il est calculé comme :

$$err_{0,632} = (1 - 0,632)err_{app} + 0,632 \varepsilon_0 \quad (3.66)$$

où

err_{app} est, utilisant les termes d'Efron, l'erreur apparente du modèle : par exemple la variance des résidus du modèle calculée sur le même ensemble utilisé pour l'estimation des paramètres, et

ε_0 est la moyenne des erreurs obtenues par des RNA entraînés avec des échantillons de bootstrap qui ne contiennent pas le point prédit, tel que

$$\varepsilon_0 = \frac{1}{n} \sum_{i=1}^n \sum_{b \in C_i} \frac{(Y_i - \hat{Y}_c | \eta_{xb})^2}{B_i} \quad (3.67)$$

où

$\hat{Y}_c | \eta_{xb}$ est l'erreur de prévision du modèle pour le cas c_i , calculée à partir de tous les modèles avec des paramètres η_{xb} , ajustés sur certains échantillons de bootstrap Xb . Les échantillons qui forment l'ensemble C_i ont en commun qu'il leur manque le cas c_i , i.e. celui-ci n'a pas été *tiré* dans le tirage des échantillons.

B_i est le nombre de ces échantillons appartenant à C_i .

n est le nombre d'observations de l'échantillon original.

Le facteur de pondération de 0,632 provient d'une démonstration théorique (Efron et Tibshirani, 1993).

3.3.10 Estimation de l'incertitude associée à la prévision

L'estimation de l'incertitude associée à la prévision est essentielle dans un modèle. Cependant, aucune des publications qui traitent des applications des RNA en hydrologie n'aborde cette question.

Les méthodes statistiques traditionnelles, que les modèles soient linéaires ou non linéaires, posent l'hypothèse que la fonction objectif (ou fonction d'erreur) à un minimum global unique. Cette hypothèse n'est pas satisfaite par les modèles de RNA. Sous certaines hypothèses, des intervalles de confiance sur la prévision peuvent être

calculés pour des RNA (Chryssolouris *et al.*, 1996 ; De Veaux *et al.*, 1998). Néanmoins, on peut obtenir des intervalles de confiance empiriques en utilisant les techniques de bootstrap sans avoir à poser des hypothèses restrictives. En fait, on peut construire, par bootstrap, deux genres d'intervalles de confiance : un sur la sortie moyenne d'un RNA et l'autre sur la réalisation future de la série à prédire. Ils sont définis comme suit :

Pour la même entrée x_0 , un intervalle de confiance à un niveau de 95% pour la sortie moyenne d'un RNA ($\hat{Y}_0$) est un intervalle $[LCI_0, LCS_0]$, tel que

$$Pr [LCI_0 \leq \hat{Y}_0 \leq LCS_0] = 0,95 \quad (3.68)$$

Pour une entrée x_0 , un intervalle de prévision à un niveau de confiance de 95% pour la réalisation future (Y_0) est un intervalle $[LPI_0, LPS_0]$, tel que

$$Pr [LPI_0 \leq Y_0 \leq LPS_0] = 0,95 \quad (3.69)$$

Un intervalle de confiance est plus étroit que l'intervalle de prévision correspondant, parce que le premier ne tient pas compte de la variation due au bruit dans la série de sortie Y_t . L'intervalle de confiance traite de la sortie moyenne du modèle, tandis que l'intervalle de prévision est celui des réalisations futures du processus. Les deux types d'intervalle, calculés par bootstrap, tiennent compte de la variabilité due à l'échantillonnage des séries d'entrée et celle causée par le processus d'apprentissage, telle que les valeurs initiales des paramètres et l'occurrence de minima locaux. Pour obtenir l'intervalle de prévision à partir de celui de confiance, il faudrait élargir ce dernier en ajoutant une fonction appropriée de la variance du bruit (Heskes, 1997).

Par exemple, pour calculer l'intervalle de confiance sur la sortie moyenne d'un RNA, n_b échantillons de bootstrap sont tirés avec remise de l'échantillon original. Pour chaque échantillon, un RNA est entraîné, pour donner n_b RNA. Les sorties des RNA sur

chaque point de l'ensemble test sont calculées par les n_b modèles, et aussi leurs variances non biaisées (Tibshirani, 1996) :

$$Var_{i(n_b)} = \sum_{i=1}^{n_b} (\hat{Y}_i - \bar{\hat{Y}})^2 / (n_b - 1) \quad (3.70)$$

En supposant que le bruit est gaussien, l'intervalle approximatif de confiance de la sortie moyenne est calculé comme :

$$\hat{Y}_i \pm 1,96 \sqrt{Var_{i(n_b)}} \quad (3.71)$$

Cet intervalle de confiance est différent d'un point à l'autre, permettant ainsi de quantifier l'incertitude associée à chaque sortie.

Quant à l'intervalle de prévision, il est calculé comme

$$\hat{Y}_i \pm 1,96 \sqrt{err_{0,632}} \quad (3.72)$$

en utilisant l'équation 3.73 qui calcule l'erreur de généralisation $err_{0,632}$. Cet intervalle s'avère plus grand (i.e. plus conservateur) que les intervalles théoriques.

Chapitre IV

DONNÉES DE L'ÉTUDE

ET ANALYSES DE CAUSALITÉ

4.1 Introduction

Comme déjà mentionné au chapitre I, la contribution majeure de cette thèse, sur le plan pratique, est l'amélioration de la prévision stochastique, à un horizon de trois mois, des volumes de la crue du Nil, en utilisant comme entrées les températures de surface de l'océan (TSO). Le succès de ce volet de recherche dépend de l'analyse des données utilisées et du choix adéquat des séries de TSO à incorporer dans les modèles de prévision. Il dépend aussi du choix des modèles de prévision comme cela sera démontré plus loin (chapitre V). Deux types de données sont employés : les débits mensuels aux stations de jaugeage sur le Nil et les TSO.

Ce chapitre est divisé en quatre grandes sections autres que la section de l'introduction. La section 4.2 présente une analyse des débits du Nil à la station de jaugeage à l'amont du Haut Barrage d'Assouan (HBA), appelée dans cette thèse station d'Assouan. L'analyse porte sur les caractéristiques statistiques de ces données, sur la variabilité interannuelle de la crue et sur la prévisibilité de cette crue trois mois à l'avance utilisant comme entrées les débits antérieurs. La section 4.3 présente la banque de données de TSO de laquelle sont extraites les variables explicatives de la crue du Nil. La description de cette banque de données, sa résolution spatiale, son étendue temporelle, ainsi que le contrôle de la qualité des données sont des points à considérer dans l'évaluation de ce genre de données. La section 4.3 se termine par la formation de plusieurs séries de TSO qui servent comme prédicteurs potentiels de la crue du Nil. La section 4.4 traite de l'analyse de causalité entre la série de la crue du Nil et celles des prédicteurs potentiels. Cette analyse vise à tester statistiquement, si les TSO "causent" la crue du Nil. Elle permet de choisir les meilleures variables explicatives à incorporer

dans les modèles de prévision. Des modèles de régression simple et multiple sont présentés à la section 4.5 pour fins de comparaison avec les modèles plus complexes de FTB et de RNA, dont l'application est faite au chapitre V.

4.2 Débits du Nil

4.2.1 Description des données disponibles

Les volumes mensuels à plusieurs stations de jaugeage ont été obtenus du ministère des Travaux Publics et des Ressources Hydriques (MTPRH) d'Égypte. La liste des huit stations et les périodes disponibles, fournies par le ministère, figurent au tableau 4.1 (cf. figure 2.5 pour la localisation de ces stations). À chaque station deux types de série sont disponibles : les débits actuels (observés) et les débits "naturalisés". Les influences des prises d'eau, de la régularisation et de l'évaporation des réservoirs artificiels ont été enlevées des débits naturalisés¹.

Tableau 4. 1 : Stations de jaugeage disponibles sur le Nil et ses tributaires

Stations de jaugeage	Tributaire jaugé	Période disponible
Mongalla	Nil Blanc	1914-1983
Malakal	Nil Blanc + Sobat	1912-1989
Roseiros	Nil Bleu	1914-1989
Sennar	Nil Bleu	1914-1989
Khartoum	Nil Bleu	1912-1989
Hassanab	Nil Blanc + Nil Bleu	1914-1988
Atbara	Atbara	1912-1989
Assouan	Nil principal	1871-1989

¹ Cette même série naturalisée a été utilisée pour la modélisation par TCPARMA (cf. section 2.5.1 de cette thèse et le rapport interne de Salas et al., 1995). Ce modèle multivarié est le modèle opérationnel au MTPRH pour la simulation des débits mensuels aux diverses stations du Nil.

La figure 4.1 représente l'hydrogramme annuel observé à six stations de jaugeage. Il est clair que les stations associées aux précipitations sur le haut plateau éthiopien (HPE) ont un hydrogramme avec une seule pointe marquée (figure 4.1 (c) à (f)). Les crues à ces stations commencent au début de juillet et ont une pointe en août.




Figure 4. 1 : Hydrogramme annuel aux stations de jaugeage sur le Nil Blanc à (a) Mongalla et à (b) Malakal ; sur le Nil Bleu à (c) Roseiros, à (d) Sennar et à (e) Khartoum et sur (f) l'Atbara

4.2.2 Débits mensuels d'Assouan

Quant à la station de jaugeage d'Assouan, qui est la station d'intérêt de cette recherche, la crue commence en juillet et a sa pointe en septembre (figure 4.2). On remarque sur la figure 4.2 que le maximum des écarts types des débits mensuels est en septembre, mais que les valeurs d'août et d'octobre sont presque aussi grandes que celle de septembre, indiquant une grande variabilité de la crue du Nil durant ces trois mois.




Figure 4. 2 : Moyenne et écart type des débits mensuels d'Assouan

Une indication de la dispersion, autre que l'écart type, est donnée par les graphiques boxplots (diagramme de Tukey) des débits mensuels (figure 4.3). La distance inter-centile ainsi que la distance entre les *moustaches* (*whiskers*), fixées à 1.5 fois la distance inter-centile, permet de quantifier la dispersion des débits mensuels. La dispersion des débits des mois d'août à octobre est beaucoup plus grande que celle des autres mois. Les boxplots indiquent aussi la présence de valeurs aberrantes qui dépassent largement les moustaches en 1945, 1972, 1984 et 1988. Il s'agira de voir, si les modèles de prévision proposés dans cette thèse peuvent prédire ces valeurs avec précision.




Figure 4. 3 : Boxplot des débits mensuels à la station d'Assouan

Conservant les mêmes critères de division des saisons proposés par Nicholson et Entekhabi (1986) (cf. section 2.2.2), mais décalant d'un mois leur calendrier compte tenu du temps de la réponse hydrologique et hydraulique du Nil, les saisons seront définies comme suit :

- l'été : de juillet à octobre,
- l'automne : de novembre à décembre,
- l'hiver : de janvier à avril, et
- le printemps : de mai à juin.

La contribution des volumes d'écoulements de chaque saison aux volumes annuels à la station d'Assouan est illustrée à la figure 4.4 (a). On remarque que les débits d'été et d'automne constituent 83 % des volumes annuels et que les débits d'été représentent 68 % des volumes annuels. La corrélation croisée entre les débits d'été et ceux

d'automne est de 0,73 et elle est significative à 95%, tandis que les corrélations croisées entre les débits d'été avec les autres débits saisonniers ne sont pas significatives à 95 %. La prévision des débits d'été est la clé d'une bonne prévision des volumes qui rentrent au HBA. On peut souligner ici que dans les modèles statistiques et stochastiques de prévision des débits d'Assouan, la lacune majeure était leur faible performance durant les mois de crue (cf. section 2.5.1).

La contribution des divers mois d'été aux volumes d'écoulements d'été est présentée à la figure 4.4 (b). Les débits d'août et de septembre sont la clé d'une bonne prévision du volume de la crue. Les débits d'août à octobre constituent 88 % du volume d'été.




Figure 4.4 : (a) Pourcentage des volumes saisonniers moyens par rapport au volume annuel moyen à Assouan (b) Pourcentage des volumes moyens des mois de juillet à octobre par rapport au volume moyen d'été à Assouan

Les faibles corrélations entre les débits saisonniers d'hiver et du printemps avec les débits d'été suggèrent de les traiter séparément. Comme déjà mentionné au chapitre II, les observations sur les deux dernières décennies fournissent l'évidence d'une différence entre les circulations atmosphériques dominant les bassins versants du Nil Blanc et du Nil Bleu (cf. sections 2.2.2 et 2.7.2). C'est pourquoi, la série des débits du

Nil qui sera prédite dans cette recherche est le volume cumulé qui rentre au HBA durant les mois de juillet à septembre. Cette série renferme donc une seule valeur par année. Elle est appelée, dans ce document, la **série d'ASSOUAN** (en majuscules) pour éviter toute confusion avec les débits annuels ou mensuels à la station d'Assouan. Elle s'étend de 1920 à 1989, soit 70 années. La limite inférieure est imposée par la disponibilité des données de TSO de bonne qualité (cf. section 4.3) et l'année 1989 est la limite supérieure des débits d'Assouan disponibles pour cette recherche (cf. tableau 4.1).

Un boxplot de la série d'ASSOUAN est illustré à la figure 4.5. On remarque trois valeurs aberrantes aux années 1945, 1984 et 1988. La prévisibilité de la série d'ASSOUAN est discutée dans la prochaine section.




Figure 4. 5 : Boxplot de la série d'ASSOUAN

4.2.3 *Prévisibilité de la crue du Nil*

Comme déjà mentionné, la montée des eaux de la crue du Nil commence en juillet, suite aux précipitations sur le HPE qui commencent en juin. Les écoulements du printemps à Assouan proviennent en grande partie du Nil Blanc (cf. figure 4.1). Pour prédire la série d'ASSOUAN connaissant seulement les écoulements précédents, que cela soit à la station d'Assouan ou à d'autres stations en amont, quatre approches sont possibles :

- (i) utiliser les débits du printemps à des stations sur le Nil Blanc,
- (ii) utiliser des débits précédents à des stations sur le Nil Bleu,
- (iii) utiliser les débits mensuels précédents à la station d'Assouan, ou
- (iv) utiliser les volumes aux années précédentes de la série d'ASSOUAN.

La figure 4.6 a et b illustre les fluctuations des débits du printemps à la station de Malakal, représentative des écoulements du Nil Blanc et du Sobat, et celles des débits d'été à Assouan de 1914 à 1989. On remarque que les fluctuations entre ces deux stations sont très différentes, voire parfois opposées, donc la première approche ne peut pas être utilisée.

Quant à la deuxième approche, elle permet un horizon de prévision qui ne dépasse pas un mois, vu que la montée des eaux aux stations liées au HPE ne commence qu'en juillet (cf. figure 4.2 (c) à (f)). Cet horizon est insuffisant pour la planification de la gestion du HBA pendant les mois d'été.

Pour vérifier la possibilité d'utiliser les débits des mois de juin par exemple, pour prédire les mois de juillet à octobre (troisième approche), les corrélations croisées sont calculées. La figure 4.7 illustre les corrélations croisées entre les débits du mois courant et les débits à un délai d'un, deux, trois et quatre mois. Supposant que les débits du mois de juin sont connus, les débits des mois d'août, septembre et octobre ne sont pas prévisibles, vu que les coefficients de corrélations (indiqués en noir) ne sont pas significatifs. De plus, le coefficient de corrélation entre les débits de juin et ceux de

juillet ne dépassant pas 0,4 ; cela est insuffisant pour construire un modèle de prévision fiable.




Figure 4. 6 : Fluctuations des écoulements du Nil Bleu et du Nil Blanc (a) volumes du printemps à Malakal (Nil Blanc) et (b) volumes d'été à Assouan.

Finalement, la quatrième approche, qui consiste en une modélisation de la série d'ASSOUAN par les modèles ARIMA, est explorée en détails à la section 4.4.1.1 où des

modèles AR(3) et MA(3) sont ajustés à la série d'ASSOUAN. Ces modèles n'expliquent que 6% de la variabilité de cette série.




Figure 4. 7 : Corrélations croisées des débits mensuels à plusieurs délais

L'exposé ci-dessus démontre l'échec des quatre approches déjà mentionnées pour prédire la crue du Nil connaissant uniquement des débits antérieurs à cette même station ou à d'autres stations en amont. La solution est d'utiliser des variables explicatives, telles que les précipitations sur le HPE ou les indices de la variabilité à l'échelle climatique. Un des indices les plus utilisés en climatologie est la température de surface de l'océan (TSO). L'utilisation des précipitations permet seulement un horizon de prévision qui ne dépasse pas le temps de réponse hydrologique, tandis que l'utilisation des TSO permet un horizon plus long, vu l'inertie thermique de l'océan. La persistance des valeurs de TSO pendant des mois est due en grande partie à cette inertie et offre la possibilité d'étendre l'horizon de prévision. La description des données de TSO fait l'objet de la prochaine section.

4.3 Températures de surface de l'océan (TSO)

Les températures de surface de l'océan (TSO) occupent une place importante dans le système couplé océano-atmosphérique qui gère, à l'échelle climatique, la formation des vents de surface, des flux humides et des courants océaniques. Ce système domine, par conséquent, la variabilité des précipitations, des températures et des pressions à la même échelle. Les TSO influencent l'évaporation de l'océan qui constitue la source majeure de l'humidité. Elles sont les variables clés à l'interface du système océano-atmosphérique, car elles gouvernent l'échange énergétique entre l'océan et l'atmosphère et sont en même temps, les résultats de cet échange. Elles sont aussi de bonnes indicatrices du système plus complexe de pressions et de vents de surface. Par conséquent, des mesures fiables des TSO permettent une bonne compréhension de la variabilité hydrologique, voire une prévision plus ou moins précise de celle-ci, dépendant des régions climatiques.

La première étape de la démarche de recherche, présentée dans cette thèse, consiste à identifier, dans une banque de données de TSO, les régions de l'océan global qui sont téléconnectées à la crue du Nil. Une fois les régions identifiées, il s'agit de former des séries temporelles en prenant la moyenne des départs de ces TSO par rapport à la moyenne à long terme de ces régions. Les séries des départs de la moyenne sont appelées les *séries d'anomalies*.

La banque de données de TSO, utilisée dans cette recherche, a été fournie par le service météorologique britannique (*United Kingdom Meteorological Office, UKMO*) sur le CD-ROM de données compilées de TSO qui porte le nom *GOSTAplus* (*Global Ocean Surface Temperature Atlas +*). Les données de cette étude sont extraites du fichier de données de TSO nommé *GISST2.2* (*Global Sea Ice and Sea Surface Temperature data set version 2.2*) qui fait partie du *GOSTAplus*. La résolution de ces données est de 1°x1°x1 mois. Les données du *GISST2.2* couvrent la période de 1903 à

1994, soit 92 années. Avant de passer à l'identification des régions téléconnectées aux écoulements du Nil, voici une description du fichier *GISST2.2* et une présentation du contrôle de la qualité effectué sur ses données.

4.3.1 Description des données

Pour constituer les banques de données de TSO, les enregistrements de mesures de températures faits par les navires sont compilés. Ces mesures sont rassemblées depuis les trois dernières décennies du 19^{ième} siècle dans la base de données du service météorologique britannique appelée la *Meteorological Office Main Marine Data Base* (MOMMDB). Cette banque de données a été complétée par :

- la banque de données *Consolidated Data Set* (CDS) tenue par le *Massachusetts Institute of Technology* (MIT) et qui rassemble les prises de TSO faites par la marine des États-Unis (*US Navy Fleet Numerical Oceanography*). Le complément est surtout remarqué pour les années 1960 et 1970 ;
- la climatologie globale d'Alexander et Mobley (AM) (1976) qui inclut des estimations faites pour des régions où les données MOMMDB-CDS sont manquantes ; et
- certaines données provenant de la *Comprehensive Ocean Atmospheric Data Set* (COADS) de Woodruff et al. (1987).

La figure 4.8 illustre le nombre d'observations disponibles dans la MOMMDB et dans la MOMMDB complétée par la COADS. On remarque l'influence des deux guerres mondiales sur la disponibilité des données. Dans plusieurs études climatiques, on fait l'usage des données commençant par les années 1950. Une série qui s'étend de 1950 à 1989 n'est pas suffisamment longue pour ajuster un modèle de prévision, d'autant plus qu'une partie de la série est réservée à la validation du modèle. Les données de TSO sont utilisées dans la présente recherche depuis l'année 1920 jusqu'à l'année 1989 (limite supérieure des données de débits), soit 70 années. Le processus de

contrôle de la qualité des données qui a abouti au *GISST2.2* est exposé à la section suivante.




Figure 4. 8 : Nombre annuel d'observations de TSO (tirée de Folland et Parker, 1995).

4.3.2 Contrôle de la qualité des données

Le processus de contrôle de la qualité des données de TSO du *GISST2.2* passe par les étapes suivantes :

- ♦ **Éliminer les données redondantes ou irréalistes** (qui sont supérieures à 37°C et qui sont inférieures à -2°C).
- ♦ **Contrôle de la qualité** : cela est réalisé en deux étapes :
 - éliminer les enregistrements individuels de TSO qui dépassent $\pm 6^\circ\text{C}$ de la moyenne de la région dans lesquelles ils sont enregistrés,
 - tronquer les valeurs aberrantes en utilisant une procédure de rognage (*trimming*) (Afifi et Azen, 1979).
- ♦ **Correction des erreurs systématiques de mesures** : au 19^{ième} siècle ainsi qu'au début du 20^{ième} siècle, les enregistrements de TSO se faisaient grâce à des seaux en toile (*canvas bucket*) non isolés ou des seaux en caoutchouc faiblement isolés. Par la suite, des seaux en bois ou en cuir mieux isolés étaient utilisés. Cependant, les effets des échanges énergétiques entre l'eau du récipient et l'environnement une fois le seau retiré de l'océan subsistaient (Folland et Parker, 1990 ; Parker et Folland, 1991). Après 1941, la méthode d'enregistrement change complètement avec la généralisation des enregistrements par prise d'eau. Folland et Parker (1995) ont modélisé le problème avec les équations complètes de transfert de chaleur et d'humidité après avoir étudié toutes les pratiques de mesures des TSO au cours des années. La correction, qu'ils ont proposée, varie selon la localisation géographique et la saison ; de plus, elle est insensible aux valeurs incertaines comme la taille des seaux. Les TSO ainsi corrigées sont plus conformes aux enregistrements de la température de l'air à la surface de la mer.
- ♦ **Fusion avec les données par satellites** : pour les données de TSO depuis 1982, les enregistrements de TSO *in situ* sont fusionnés avec les estimations de ces TSO à partir des images par AVHRR (*Advanced Very High Resolution Radiometer*). Cette fusion de données permet de corriger les biais systématiques dans les estimations par images satellitaires (Reynolds, 1988), tout en assurant une couverture plus globale.

Après cette brève description de la banque de données du service météorologique britannique, la prochaine section présente la procédure utilisée pour la formation des séries des moyennes de TSO à certaines régions qui servent comme prédictors potentiels de la série d'ASSOUAN.

4.3.3 Choix des prédictors potentiels de la série d'ASSOUAN

L'identification des régions de l'océan global où les TSO influencent la crue du Nil est une tâche complexe, vu le grand nombre de données de TSO. Elle est basée, en premier lieu, sur les études climatologiques qui ont traité de la climatologie du haut plateau éthiopien (HPE).

La figure 4.9 (adaptée de Folland *et al.*, 1991) illustre les vents de surface qui influencent le HPE. On remarque que le HPE est sujet à des vents qui proviennent des océans Indien et Atlantique. Reste à déterminer quelles régions de ces océans pourraient être représentatives de la variabilité des TSO et en plus être des prédictors de la crue du Nil avec un horizon de prévision qui dépasse le temps de réponse hydrologique et hydraulique du bassin du Nil. Un tel horizon, pourvu que le modèle de prévision soit fiable, offre une utilité opérationnelle.




Figure 4. 9 : Vents de surface en été qui atteignent le HPE
(d'après Folland *et al.*, 1991)

Basé sur les études climatologiques présentées aux sections 2.2 et 2.6, il faut aussi ajouter à l'Atlantique et à l'océan Indien, qui sont les sources des flux de moussons, la région d'El-Niño (au Pacifique est). Donc, les TSO liées à la crue du Nil et aux précipitations sur le haut plateau éthiopien (HPE) se situent au Pacifique est (région El-Niño), à l'Atlantique sud et à l'océan Indien. Les TSO sont celles du mois de juin, considérées représentatives des TSO de la saison. Cela permet de prédire la crue du Nil trois mois avant l'occurrence de la pointe de celle-ci.

4.3.3.1 Pacifique est

Suivant Eltahir (1996), Amaresekera et al. (1997), Wang et Eltahir (1999), et Piechota et Dracup (1999), un indice de l'ENSO proposé par Wright (1989) est utilisé pour la prévision des débits. Cet indice, appelé *indice homogénéisé*, est formé en prenant la moyenne des anomalies de TSO au Pacifique sur la région qui couvre de 6°N à 12°N, et 179°O à 90°O ; de 2°N à 6°S et 180°O à 90°O ; de 6°S à 10°S et 150°O à 110°O.

La région choisie par Wright est en accord avec les régions du Pacifique qui sont significativement corrélées avec les débits des tributaires du Nil Bleu (figure 4.10 tirée de Bhatt, 1989, p.1139) et avec les précipitations sur le haut plateau éthiopien (figure 4.11 tirée de Camberlin, 1994, p.295). Cette série de TSO sera appelée WRHOM pour *Wright Homogénéisé*.

4.3.3.2 Océan Indien

Pour l'océan Indien, on remarque sur les figures 4.10 et 4.11 que les corrélations sont moins significatives et que l'uniformité spatiale est moins forte. Une seule région de l'océan Indien possède des corrélations significatives avec le bassin du Nil tout en conservant une uniformité spatiale. Cette région se situe près de l'île de Madagascar (de

20°S à 40°S et 50°E à 80°E, figure 4.11) à la trace au sol de la source du jet de Somalie responsable du flux de mousson indien (figure 4.9). La série est appelée STHIND.




Figure 4. 10 : Corrélations entre les débits de juillet et d'août à Roseiros et les TSO aux mêmes mois, calculées sur la période 1948-1972 (tirée de Bhatt, 1989)




Figure 4. 11 : Corrélations entre les précipitations sur le HPE de juillet à septembre et les TSO aux mêmes mois, calculées sur la période 1953-1988 (tirée de Camberlin, 1994).

4.3.3.3 Atlantique sud

L'Atlantique sud tout entier est négativement corrélé avec les débits des tributaires du Nil Bleu (figure 4.10) et avec les précipitations sur le HPE (figure 4.11). L'équateur météorologique fait la séparation entre les régions corrélées négativement dans l'Atlantique sud et les régions corrélées positivement dans l'Atlantique nord. Il se situe à la trace au sol de l'axe de confluence de la ZCIT.

La série STHATL est constituée en calculant la moyenne des anomalies de TSO sur tout l'Atlantique au sud de l'équateur météorologique. Deux autres sous-régions de l'Atlantique sud sont corrélées significativement avec les précipitations sur le HPE :

- une bande de 10° juste au sud de l'équateur météorologique, et
- une région près de la côte namibienne (de 15°S à 35°S et 10°O à 10°E), à la trace au sol du flux de mousson sahélien (figure 4.9).

La première série est appelée ATLEQU et la deuxième ATLNAM.

Les séries WRHOM, STHIND, STHATL et ATLNAM sont illustrées à la figure 4.12 a et b. Les départs par rapport à la moyenne de la série d'ASSOUAN sont représentés en barres grises sur la même figure pour comparer l'allure des séries de TSO avec celle d'ASSOUAN. Les graphiques suggèrent une connexion opposée entre les séries de TSO et ASSOUAN, i.e. une association entre la réduction des apports naturels et le réchauffement de l'océan dans les régions choisies. Cela est plus remarqué pour la série WRHOM.

Les régions de TSO qui ont servi à former les séries : WRHOM, STHIND, STHATL, ATLEQU et ATLNAM, prédictes potentiels de la crue du Nil, comme expliqué ci-dessus, sont illustrées à la figure 4.13. Les séries des moyennes des anomalies de TSO dans ces régions au mois de juin sont standardisées, i.e. la moyenne de la série à long terme est soustraite et la différence est divisée par l'écart type. Les séries standardisées sont appelées les *anomalies standardisées*.





Figure 4. 12 : Départs standardisés de la moyenne du volume de la crue d'été (ASSOUAN) et des TSO (a) WRHOM et STHIND et (b) STHATL et ATLNAM



ATLEQU Moyenne des anomalies de TSO sur une bande de 10° au sud de l'équateur météorologique

ATLNAM Moyenne des anomalies de TSO sur une région près de la côte namibienne au sud de l'Atlantique (de 15°N à 35°N et de 10°O à 10°E)

HPE Haut plateau éthiopien (région à ombrage plus foncé)

EM Équateur météorologique (ligne brisée)

STHIND Moyenne des anomalies de TSO sur une région de 20°S à 40°S et 50°E à 80°E (dans l'océan indien sud)

WRHOM Indice de l'ENSO proposé par Wright (1989) constitué en faisant la moyenne des TSO sur une région qui s'étend de 6°N à 12°N, et 179°O à 90°O ; de 2°N à 6°S et 180°O à 90°O ; de 6°S à 10°S et 150°O à 110°O (au Pacifique est)

Figure 4. 13 : Localisation des régions de TSO utilisées comme prédicteurs potentiels de la crue du Nil.

4.4 Analyse de causalité

Granger (1969) définit la causalité entre deux séries temporelles en fonction de la prévisibilité : une variable X_t est la cause d'une variable Y_t , si la variable actuelle Y_t peut être mieux prédite en utilisant les valeurs passées de X_t qu'en ne le faisant pas. Toute autre information, incluant les valeurs passées de Y_t , est utilisée dans les deux cas. Cette

définition de la causalité ne fait pas l'hypothèse que le système est linéaire. Cependant, si l'hypothèse de linéarité est posée, les prévisions linéaires peuvent être comparées (Hipel et McLeod, 1994).

Il existe plusieurs tests formels de causalité, comme cela sera présenté plus loin (section 4.4.2). Ces tests sont basés sur le "préblanchissage" des séries d'entrée et de sortie, qui consiste à trouver les meilleurs modèles ARIMA pour chacune de ces séries. Comme déjà mentionné au chapitre III, les résidus de ces modèles sont appelés les *innovations*. Les résultats des tests de causalité entre deux séries sont plus fiables, s'ils sont faits sur les innovations. De fait, si les entrées X_t et les sorties Y_t sont autocorrélées, les estimations de la fonction de corrélation croisée (FCC) à différents délais de temps pourraient être corrélées entre elles (Bartlett, 1966) donnant des résultats erronés du test. D'autre part, le préblanchissage n'affecte pas le moteur qui gouverne la relation entre les deux séries (Hipel et McLeod, 1994).

La modélisation de chacune des séries de sortie et d'entrée constitue donc la première étape de l'analyse de causalité. Elle est présentée dans le texte qui suit.

4.4.1 Modélisation de chacune des séries d'entrée et de sortie

4.4.1.1 Modélisation de la série ASSOUAN

La figure 4.14 (a et b) montre, respectivement, la fonction d'autocorrélation (FAC) et la fonction d'autocorrélation partielle (FACP). En regardant les résultats, on peut suggérer soit un bruit blanc, si on néglige le poids au 3^{ième} délai de la FAC (modèle A), un modèle autorégressif d'ordre 3 (AR(3), modèle B) ou bien un modèle à moyenne mobile d'ordre 3 (MA(3), modèle C), avec uniquement le 3^{ième} paramètre à estimer dans les deux derniers cas. Ces deux modèles sont ajustés à la série d'ASSOUAN.




Figure 4. 14 : (a) Fonction d'autocorrélation (FAC) et (b) fonction d'autocorrélation partielle (FACP) de la série d'ASSOUAN

L'estimation des paramètres des modèles, la variance estimée du bruit (σ_e^2), le coefficient de détermination (R^2) et le coefficient d'information bayésien (CIB) sont tabulés pour les trois modèles (tableau 4.2). Le meilleur modèle aurait un R^2 plus élevé et des σ_e^2 et CIB plus petits. Selon les trois critères, le modèle C, soit MA(3), est le meilleur, bien qu'il explique uniquement 6% de la variabilité. Quel que soit le modèle choisi, le bruit a presque la même variance que la série originale d'ASSOUAN (modèle A).

Tableau 4. 2 : Comparaison entre les modèles ARMA pour la série d'ASSOUAN

Modèle	Paramètres	Estimation	Erreur Std.	R^2	σ_e^2	CIB
A	Bruit Blanc			0,0	0,240 E-01	-3,728
B	CONST	4,0437	0,0254	2,9	0,233 E-01	-3,699
	ϕ_3	0,2678	0,1261			
C	CONST	4,0418	0,0220	6,0	0,226 E-01	-3,729
	θ_3	-0,2351	0,1158			

4.4.1.2 Modélisation de la série WRHOM

La série WRHOM est formée, comme déjà mentionné, en prenant la moyenne des anomalies de TSO dans une région spécifique du Pacifique est. La FAC et la FACP de WRHOM (figure 4.15 a et b) suggèrent que la série est un bruit aléatoire, donc modélisée par un bruit blanc à variance égale à 1,0. Le test modifié de Portemanteau de Ljung et Box (1978) sur les résidus (cf. section 3.2.5) est accepté pour des délais $L=20$ et $L=30$.

La corrélation croisée à décalage nul, entre les innovations de la série WRHOM (qui sont les mêmes que la série WRHOM, car celle-ci est un bruit blanc) et les innovations d'ASSOUAN, est égale à $-0,56$, calculée sur la période 1920-1989 (figure 4.19a).




Figure 4. 15 : (a) Fonction d'autocorrélation (FAC) et (b) fonction d'autocorrélation partielle (FACP) de la série de WRHOM

4.4.1.3 Modélisation de la série STHIND

La FAC de la série STHIND (moyennes des anomalies de TSO dans une région de l'océan Indien sud) (figure 4.16 a) montre une tendance qui diminue lentement ce qui confirme la non-stationnarité de la série indiquant l'adéquation d'un modèle ARIMA (0,1,1). Le modèle explique 39% de la variance et passe le test du Portemanteau. La corrélation croisée à décalage nul, entre les innovations de STHIND (après le filtrage par

ARIMA (0,1,1)) et les innovations d'ASSOUAN, est égale à $-0,35$, calculée sur la période 1920-1989 (figure 4.19b).




Figure 4. 16 : (a) Fonction d'autocorrélation (FAC) et (b) fonction d'autocorrélation partielle (FACP) de la série de STHIND

4.4.1.4 Modélisation des séries de l'Atlantique sud :

La série ATLEQU (moyenne des anomalies de TSO sur une bande de 10° de latitude au sud de l'équateur météorologique) est significativement corrélée avec la série d'ASSOUAN pour les mois de crue seulement (juillet à octobre). Donc, elle ne peut pas être utilisée pour prédire d'avance la série ASSOUAN. Par contre, les deux autres séries considérées de l'Atlantique (ATLNAM et STHATL) sont significativement corrélées

avec ASSOUAN depuis le mois de mai et jusqu'à septembre. Cette constatation est en accord avec les résultats de Nicholson (1997) sur l'évolution des TSO dans l'Atlantique.

La série ATLNAM, formée en prenant la moyenne des anomalies de TSO près de la côte namibienne au sud de l'Atlantique, est modélisée par un processus MA(1). La FAC et la FACP sont illustrées à la figure 4.17 a et b.




Figure 4. 17 : (a) Fonction d'autocorrélation (FAC) et (b) fonction d'autocorrélation partielle (FACP) de la série de ATLNAM

La série STHATL, formée par la moyenne des anomalies de TSO sur tout l'Atlantique au sud de la position estivale de l'équateur météorologique, pourrait être

modélisée par un processus AR(4) avec des paramètres au deuxième et au quatrième délai seulement à estimer comme le suggèrent la FAC et la FACP de STHATL (figure 4.18). La corrélation croisée entre les innovations d'ATLNAM et celles d'ASSOUAN est plus élevée que celle entre les innovations de STHATL et celles d'ASSOUAN.




Figure 4. 18 : (a) Fonction d'autocorrélation (FAC) et (b) fonction d'autocorrélation partielle (FACP) de la série de STHATL

Une analyse plus poussée révèle une dégradation de la corrélation croisée pour la période avant 1945 comparée à celle sur toutes les années, i.e. $r_{1920-1989} = -0,36$ (figure 4.19c) mais $r_{1946-1989} = -0,56$ (figure 4.19d). La même remarque a été faite par Parker et

al. (1988) qui ont utilisé un indice de la précipitation au Sahel. La série ATLNAM sera introduite comme un prédicteur potentiel de la série d'ASSOUAN.

4.4.2 Tests de causalité

Plusieurs tests formels ont été développés pour tester la signification de la causalité entre les innovations (Haugh, 1976; Pierce, 1977; McLeod, 1979). S'il est reconnu, à priori, à travers les caractéristiques physiques du système modélisé par exemple, que la variable de sortie n'est pas la cause de la variable d'entrée, Haugh (1976) et aussi Pierce (1977) ont formulé la statistique du test de causalité comme :

$$Q_L = N^2 \sum_{k=0}^L (N-k)^{-1} r_{uv}^2(k) \quad (4.1)$$

où

$r_{uv}(k)$ est le coefficient de corrélation croisée au délai k entre les innovations (u_t) de la série d'entrée (X_t) et les innovations (v_t) de la série de sortie (Y_t) ;

L est choisi de telle manière qu'après L unités de temps, on s'attendrait à ne pas avoir de relations entre la série d'entrée et la série de sortie (Hipel et McLeod, 1994) ;

Q_L suit approximativement une distribution χ^2 , avec $L+1$ degré de liberté. Si Q_L dépasse χ_{L+1}^2 au niveau de confiance désiré, on déduit l'existence de causalité significative entre X_t et Y_t .

Granger (1980) et Granger et Newbold (1986) ont postulé que la statistique du test de Haugh / Pierce est biaisée : elle tend moins vers la conclusion de signification de la causalité. Donc, si en utilisant ce test, les résultats confirment une relation de cause à effet, ceci est une forte indication de l'existence statistique de cette relation.

La figure 4.19 (a, b, c et d) montre les FCC entre d'une part, les innovations des séries WRHOM, STHIND, ATLANAM 1920-1989 et ATLNAM 1945-1989, et d'autre

part, celles d'ASSOUAN. Les figures 4.19 (a à d) montrent des pointes très significatives au délai $k=0$.




Figure 4. 19 : Fonction de corrélation croisée (FCC) entre les innovations des séries
(a) WRHOM, (b) STHIND, (c) ATLNAM₁₉₂₀₋₁₉₈₉ et (d) ATLNAM₁₉₄₅₋₁₉₈₉
et les innovations d'ASSOUAN

La statistique de test Q_L est tabulée pour les délais 0, 2, 3, 5, 10, 15, 20 et 24 pour les FCC mentionnées ci-dessus (tableau 4.3). La relation causale est acceptée, au niveau de confiance de 95%, jusqu'au délai 20 pour la série WRHOM, seulement jusqu'au délai 3 pour la série STHIND et jusqu'au délai 10 pour la série ATLNAM. Le délai maximal de 20 pour la série WRHOM est difficile à expliquer par une téléconnexion physique directe entre les TSO de la région du Pacifique est et la crue d'été du Nil. Il est probablement dû à la nature récurrente de l'événement ENSO.

Tableau 4. 3 : Statistique Q_L du test de causalité entre d'une part, les séries WRHOM, STHIND et STHATL et d'autre part, la série d'ASSOUAN, avec les valeurs critiques du test au niveau de confiance de 95%

Délai (L)	La statistique Q_L du test de causalité entre ASSOUAN et			Valeurs critiques de χ^2_{L+1}
	WRHOM	STHIND	ATLNAM	
0	21,29	8,67	9,89	<i>3,84</i>
2	22,07	9,79	11,54	<i>7,81</i>
3	22,24	9,79	12,05	<i>9,49</i>
5	24,59	11,48	13,20	<i>12,59</i>
10	29,77	16,25	20,18	<i>19,68</i>
15	32,72	19,94	21,21	<i>26,30</i>
20	33,64	21,86	22,76	<i>32,67</i>
24	37,38	24,72	28,15	<i>37,65</i>
Les valeurs significatives sont en gras et les valeurs critiques χ^2_{L+1} sont en <i>italique</i> .				

4.5 Modèles de régression entre le TSO et ASSOUAN

Utilisant les trois prédicteurs potentiels identifiés selon les études climatologiques publiées dans la littérature et les analyses de causalité effectuées à la section précédente, trois modèles de régression simple sont ajustés :

Modèle D_R :

$$ASSOUAN = f(WRHOM) \quad (4.2)$$

Modèle E_R :

$$ASSOUAN = f(STHIND) \quad (4.3)$$

Modèle F_R :

$$ASSOUAN = f(ATLNAM) \quad (4.4)$$

Trois autres modèles de régression multiple sont ajustés pour prédire la série d'ASSOUAN en incorporant la série WRHOM dans ces trois modèles, car elle possède le coefficient de corrélation croisée le plus élevé avec la série d'ASSOUAN. Le premier modèle (G_R) a WRHOM et STHIND comme entrées, le second (H_R) a WRHOM et ATLNAM comme entrées et le troisième (I_R) a les trois séries WRHOM, STHIND et ATLNAM comme entrées. L'indice R dans l'appellation des modèles se réfère à *régression*.

Le tableau 4.4 montre une comparaison entre les différents modèles de régressions simple et multiple, selon leurs paramètres, leurs coefficients de détermination ajustés et la variance de leurs résidus. Les paramètres associés à la série ATLNAM sont statistiquement non significatifs. Le meilleur modèle est G_R , vu qu'il a le coefficient de détermination ajusté le plus élevé. Ce critère est suffisant pour choisir le meilleur modèle de régression.

La régression linéaire a permis d'établir un lien entre la crue du Nil et les TSO, cependant avec un R^2 qui ne dépasse pas 30 %, ce modèle ne peut pas être utilisé de façon fiable pour la prévision de la crue du Nil. Le chapitre V présente la prévision de la crue du Nil avec les mêmes séries de TSO comme entrées, mais avec les modèles de fonction de transfert avec bruit (FTB) et les réseaux de neurones artificiels (RNA) déjà présentés au chapitre III. Les prévisions obtenues par ces deux modèles donnent des résultats nettement meilleurs que ceux obtenus par régression linéaire.

Tableau 4. 4 : Comparaison entre les modèles de régression

Modèle	Paramètres	Estimation	Erreur Std.	R^2	σ_e^2
Modèles de régression simple					
D_R	CONST	4,06541	0,01556	21,7	0,012
	WRHOM	-0,06926	0,01816		
E_R	CONST	4,04360	0,01842	13,6	0,013
	STHIND	-0,06050	0,02047		
F_R	CONST	4,06546	0,01767	1,1	0,015
	ATLNAM	-0,04740	0,03826		
Modèles de régression multiple					
G_R	CONST	4,04819	0,01696	27,3	0,011
	WRHOM	-0,05782	0,01827		
	STHIND	-0,04260	0,01962		
H_R	CONST	4,06398	0,01584	20,6	0,012
	WRHOM	-0,06690	0,01868		
	ATLNAM	-0,02141	0,03503		
I_R	CONST	4,04818	0,01714	25,7	0,011
	WRHOM	-0,05769	0,01862		
	STHIND	-0,04230	0,02059		
	ATLNAM	-0,00190	0,03520		

Chapitre V

MODÉLISATION ET PRÉVISION

PAR FONCTIONS DE TRANSFERT AVEC BRUIT

ET PAR RÉSEAUX DE NEURONES ARTIFICIELS

5.1 Introduction

Ce chapitre a pour but de présenter les applications des modèles de fonctions de transfert avec bruit (FTB) et de réseaux de neurones artificiels (RNA) pour la prévision de la crue du Nil en utilisant comme variables exogènes les températures de surface de l'océan (TSO). Les fondements théoriques des deux méthodes de prévision sont détaillés au chapitre III et les données utilisées sont décrites au chapitre IV. Ces applications constituent les premières des FTB et des RNA pour modéliser directement la relation entre les TSO et les débits. Les modèles offrent des potentialités intéressantes d'utilisation opérationnelle, car leur performance en prévision est plus élevée que les modèles publiés dans la littérature et que les modèles de régression linéaire présentés à la section 4.5.

La démarche, qui mène à la construction des modèles de FTB et de RNA proposés dans ce travail de recherche, commence par l'identification des indices climatiques prédicteurs de la crue du Nil, basée sur les études climatologiques et les analyses de causalité. Trois prédicteurs sont retenus au chapitre IV, soit WRHOM, STHIND et ATLNAM (cf. section 4.3.3). Ces prédicteurs sont incorporés comme variables exogènes dans les modèles de prévision par FTB et RNA avec les composantes de délai de la série de sortie ASSOUAN. Bien que, théoriquement, rien n'empêche de construire directement des modèles de FTB ou de RNA à plusieurs variables exogènes, commencer par construire plusieurs modèles à une variable exogène permet une

meilleure identification des structures des modèles et une compréhension plus précise de leurs comportements.

Ce chapitre est subdivisé en quatre sections autres que celle de l'introduction. La section 5.2 de ce chapitre présente la construction des modèles de FTB et les résultats obtenus par ces modèles et la section 5.3 présente la construction des modèles de RNA et leurs résultats. Une fois les modèles construits et validés, une comparaison des résultats des deux types de modèles est élaborée à la section 5.4. Cette comparaison est basée sur le pourcentage de la variabilité (R^2) de la crue du Nil expliqué par chaque modèle, sur la variance des résidus, mais surtout sur l'erreur de généralisation calculée par le coefficient d'information bayésien (*CIB*) (Schwarz, 1978) et sur la performance en prévision de chaque modèle. La section 5.4 se termine par une comparaison entre les résultats des modèles proposés dans cette thèse et ceux des modèles publiés dans la littérature. La section 5.5 est consacrée à une interprétation des comportements des modèles proposés fondée sur les études récentes en climatologie.

5.2 Modèles de FTB

Les modèles de FTB sont développés suivant les trois étapes classiques de Box et Jenkins (1976) décrites au chapitre III. Des FTB à une variable exogène (section 5.2.1), puis des FTB à plusieurs variables exogènes (section 5.2.2), sont construites et validées. Plusieurs modèles possibles sont développés. La validation de ces modèles est faite tout d'abord par l'inspection visuelle de la fonction de corrélation croisée (FCC) entre les innovations des séries de variables exogènes et les résidus des modèles de FTB. Cette inspection permet de détecter les anomalies dans la structure de la fonction impulsion-réponse. Ensuite, on procède à l'inspection visuelle de la fonction de l'autocorrélation (FAC) et de celle d'autocorrélation partielle (FACP) pour vérifier si les résidus sont indépendants et par conséquent, de l'adéquation du modèle de bruit. Dans

le cas de l'application traitée dans ce chapitre, peu d'importance est donnée aux poids significatifs isolés détectés pour des délais négatifs. Il est difficile de justifier que la crue du Nil puisse influencer les températures de surface de l'océan. La relation entre les deux variables n'est donc pas un système à feed-back et par conséquent, la présence de ces poids significatifs ne représente pas une violation de la première hypothèse des FTB (cf. Section 3.2.2). Les tests modifiés de Portemanteau sur les coefficients d'autocorrélation (équation 3.20) et sur les coefficients de corrélations croisées (équations 3.21 et 3.23) sont aussi entrepris. Le meilleur modèle est celui qui possède la plus petite erreur de généralisation calculée selon le coefficient d'information bayésien (*CIB*).

5.2.1 Modèles de FTB avec une seule variable exogène de TSO

Basé sur l'analyse de causalité entre les TSO et la série d'*ASSOUAN* (cf. section 4.4) ainsi que sur la revue de littérature sur les forçages climatiques qui agissent sur les précipitations aux sources du Nil (cf. section 2.6), trois modèles de FTB à une variable exogène de TSO sont construits :

Modèle D_T :

$$ASSOUAN = f(WRHOM, ASSOUAN) \quad (5.1)$$

Modèle E_T :

$$ASSOUAN = f(STHIND, ASSOUAN) \quad (5.2)$$

Modèle F_T :

$$ASSOUAN = f(ATLANTIQUE, ASSOUAN) \quad (5.3)$$

Deux séries de TSO de l'Atlantique, *ATLNAM* et *STHATL* déjà présentées au chapitre IV, sont incluses, une à la fois, dans le modèle F_T pour choisir la meilleure dans la prévision de la série d'*ASSOUAN*. Une seule est à choisir, pour éviter d'inclure des variables exogènes possédant de fortes corrélations entre elles. Le modèle avec *ATLNAM* comme unique variable exogène possède un R^2 de 22,5% et un coefficient d'information bayésien (*CIB*) de $-3,742$, tandis que le modèle avec *STHATL* comme variable exogène possède un R^2 de 9% et un *CIB* de $-3,697$. Déjà, la série *ATLNAM* a la corrélation croisée la plus élevée avec le Nil parmi les séries du sud de l'Atlantique (cf. section 4.4). Dorénavant, la série *ATLNAM* sera la seule considérée, parmi celles de l'Atlantique, dans les modèles de FTB et le modèle F_T sera défini comme :

$$ASSOUAN = f(ATLNAM, ASSOUAN) \quad (5.4)$$

Deux modèles de FTB, avec *WRHOM* comme unique variable exogène, sont construits : D_{T1} et D_{T2} . En examinant la FCC entre les résidus du modèle D_{T1} et les résidus de la série d'entrée (*WRHOM*) (figure 5.1 a et b), aucune valeur significative n'est détectée. Cependant le modèle D_{T2} a été construit avec un paramètre du septième délai en plus de celui du délai zéro. Ce modèle servira pour la comparaison avec le modèle J_T à plusieurs variables exogènes détaillé à la prochaine section. L'erreur de généralisation du modèle D_{T2} est légèrement supérieure à celle du modèle D_{T1} , malgré le terme de pénalité (équation 3.32) augmenté par le paramètre additionnel. Le test de Pitman (Pitman, 1939) permet une comparaison plus rigoureuse entre les différents modèles (cf. section 5.2.4).

Le modèle E_T a un coefficient légèrement significatif au troisième délai du côté négatif (figure 5.2). Cependant, comme déjà mentionné dans l'introduction, il est difficile de justifier que la crue du Nil puisse influencer les températures de surface de l'océan, et par conséquent, la présence de ces poids significatifs ne peut pas suggérer un système à feed-back.




Figure 5. 1 : Fonction de corrélation croisée (FCC) entre les innovations de la série *WRHOM* et les résidus des modèles (a) D_{T1} et (b) D_{T2}




Figure 5. 2 : Fonction de corrélation croisée (FCC) entre les innovations de la série *STHIND* et les résidus du modèle E_T

Trois modèles de type F_T , avec $ATLNAM$ comme unique variable exogène, sont construits : F_{T1} , F_{T2} et F_{T3} . Le modèle F_{T1} , avec $ATLNAM$ comme variable exogène et un seul paramètre au délai 0, montre dans sa FCC, un poids significatif au délai 1 (figure 5.3 a). Après avoir inclus un paramètre à ce délai dans le modèle F_{T2} , un autre poids significatif au sixième délai apparaît (figure 5.3 b). Le modèle F_{T3} , avec des paramètres aux délais 0, 1 et 6, est meilleur avec un CIB légèrement plus petit.

Les FCC entre d'une part les innovations des séries des variables exogènes ($WRHOM$ (figure 5.1 b), $STHIND$ (figure 5.2) et $ATLNAM$ (figure 5.3 c), respectivement) et d'autre part, les résidus des modèles D_{T2} , E_T et F_{T3} ne montrent pas de valeurs significatives pour tous les délais positifs ; ce qui est en parfait accord avec les hypothèses de la modélisation par FTB.

Les graphiques des résidus des modèles de FTB D_{T2} , E_T et F_{T3} ne montrent aucun patron particulier. Les FAC (figure 5.4) et les FACP indiquent que les résidus sont indépendants. D'ailleurs, les tests modifiés de Portemanteau (Ljung et Box, 1978) sont tous acceptés au niveau de confiance de 95%.

L'estimation des paramètres et la structure du terme de bruit des modèles de FTB à une variable exogène sont résumées au tableau 5.1 avec trois critères pour comparer les modèles : le coefficient de détermination (R^2), la variance des résidus (σ_e^2) et le coefficient d'information bayésien (CIB). Le meilleur modèle posséderait un R^2 plus élevé et des σ_e^2 et CIB plus petits. Les comparaisons les plus importantes restent cependant la performance en prévision des modèles sur un ensemble de données qui n'est pas utilisé pour l'estimation des paramètres des modèles (cf. section 5.2.3) et les tests de signification de la différence entre les variances des résidus des modèles (cf. section 5.2.4).




Figure 5.3 : Fonction de corrélation croisée (FCC) entre les innovations de la série *ATLNAM* et les résidus des modèles (a) F_{T1} , (b) F_{T2} et (c) F_{T3}




Figure 5.4 : Fonction d'autocorrélation (FAC) des résidus des modèles (a) D_{T2} , (b) E_T et (c) F_{T3}

Le coefficient de détermination R^2 n'est pas un critère répandu pour évaluer les modèles Box et Jenkins (ou ceux des RNA). Il peut même mener à de fausses conclusions (Liu *et al.*, 1994). Malgré cela, il est utilisé dans ce travail pour fins de comparaison avec les résultats publiés dans la littérature (chapitre II) (p. ex. Lin, 1995a, b, et c; Eltahir, 1996; Gissila, 1997; Amarasekera *et al.*, 1997), ainsi que les modèles de régression linéaire ajustés au chapitre IV.

Tableau 5. 1 : Comparaison entre les modèles de FTB à une variable exogène

Modèle	Paramètres	Estimation	Erreur Std.	R^2	σ_e^2	CIB
D_{T1}	CONST	4,0424	0,0208	36,4	0,153 E-01	-3,937
	WRHOM ₀	-0,0855	0,0135			
	WRHOM ₇	-0,0377	0,0159			
	$N_t = (1 - \theta_2 B^2) \cdot e_t$ θ_2	-0,3668	0,1131			
D_{T2}	CONST	4,0379	0,0202	34,4	0,158 E-01	-3,966
	WRHOM ₀	-0,0834	0,0135			
	$N_t = (1 - \theta_2 B^2) \cdot e_t$ θ_2	-0,3697	0,1103			
E_T	CONST	4,0414	0,0133	22,1	0,187 E-01	-3,797
	STHIND ₀	-0,0739	0,0149			
	$N_t = 1/(1 - \phi_1 B^4) \cdot e_t$ ϕ_1	-0,2711	0,1282			
F_{T1}	CONST	4,0471	0,0176	10,7	0,214 E-01	-3,723
	ATLNAM ₀	-0,0978	0,0338			
	$N_t = e_t$					
F_{T2}	CONST	4,0454	0,0172	16,3	0,201 E-01	-3,725
	ATLNAM ₀	-0,0978	0,0347			
	ATLNAM ₁	0,0812	0,0347			
	$N_t = e_t$					
F_{T3}	CONST	4,0477	0,0174	22,5	0,186 E-01	-3,742
	ATLNAM ₀	-0,1103	0,0346			
	ATLNAM ₁	0,0927	0,0345			
	ATLNAM ₆	-0,0982	0,0353			
	$N_t = e_t$					

5.2.2 Modèles de FTB à plusieurs variables exogènes

Intuitivement, il n'y a pas de raisons pour penser que les composantes au délai zéro de la fonction impulsion-réponse des modèles à une variable exogène (modèles D_{T1} , D_{T2} , E_T , F_{T1} à F_{T3}) vont changer de manière importante une fois les variables exogènes incorporées dans un modèle à plusieurs variables exogènes. Vu que les modèles avec WRHOM comme variable exogène sont les meilleurs parmi les modèles déjà proposés (cf. tableau 5.1), cette variable sera incorporée dans tous les modèles à plusieurs variables exogènes. La variable STHIND est introduite au modèle G_T , la variable ATLNAM au modèle H_T et ensuite les deux variables ensemble au modèle I_T .

Modèle G_T :

$$ASSOUAN_t = C + (WRHOM_0) \cdot WRHOM_t + (STHIND_0) \cdot STHIND_t + N_t \quad (5.5)$$

Modèle H_T :

$$ASSOUAN_t = C + (WRHOM_0) \cdot WRHOM_t + (ATLNAM_0) \cdot ATLNAM_t + N_t \quad (5.6)$$

Modèle I_T :

$$ASSOUAN_t = C + (WRHOM_0) \cdot WRHOM_t + (STHIND_0) \cdot STHIND_t + (ATLNAM_0) \cdot ATLNAM_t + N_t \quad (5.7)$$

La FCC des innovations de la série WRHOM avec les résidus du modèle G_T , montre une valeur légèrement significative au septième délai (figure 5.5 a), ce qui suggère la construction du modèle J_T , avec un paramètre à ce délai, qui est plus conforme à la 2^{ème} hypothèse de modélisation par FTB. Les structures des modèles ARMA pour le terme de bruit des modèles G_T et J_T sont respectivement :

$$N_t = (1 - \theta_2 B^2 - \theta_4 B^4) \cdot e_t \quad (5.8)$$

et

$$N_t = \frac{(1 - \theta_4 B^4 - \theta_5 B^5)}{(1 - \phi_1 B)} e_t \quad (5.9)$$

Les FCC entre les innovations des séries de variables exogènes utilisées (*WRHOM* et *STHIND*) et les résidus du modèle G_T et J_T sont illustrées aux figures 5.5 et 5.6. La FAC des résidus du modèle J_T (figure 5.7) montre que ceux-ci sont indépendants. Bien que le nombre de paramètres du modèle J_T soit relativement plus grand que les autres modèles, son *CIB* reste inférieur (tableau 5.2).




Figure 5.5 : Fonction de corrélation croisée (FCC) entre d'une part, les innovations des séries (a) *WRHOM* et (b) *STHIND* et d'autre part, les résidus du modèle G_T




Figure 5. 6 : Fonction de corrélation croisée (FCC) entre d'une part, les innovations des séries (a) *WRHOM* et (b) *STHIND* et d'autre part, les résidus du modèle J_7




Figure 5. 7 : Fonction d'autocorrélation (FAC) des résidus du modèle J_7

Le tableau 5.2, comme le tableau 5.1, présente l'estimation des paramètres, la structure du terme de bruit, et les critères de comparaison (R^2 , σ_e^2 , CIB) des modèles de FTB à plusieurs variables exogènes. Le paramètre $ATLNAM_0$, associé à la série $ATLNAM$ dans le modèle I_T , est non significatif et le CIB du modèle I_T est plus grand que celui du modèle G_T (tableau 5.2). Le modèle I_T , après avoir enlevé $ATLNAM$, est réduit au modèle G_T . Dans l'exposé qui suit, les modèle I_T ne sera plus considéré.

Tableau 5.2 : Comparaison entre les modèles de FTB à plusieurs variables exogènes

Modèle	Paramètres	Estimation	Erreur Std.	R^2	σ_e^2	CIB
G_T	CONST	4,0416	0,0132	44,4	0,132 E-01	-4,024
	WRHOM ₀	-0,0692	0,0131			
	STHIND ₀	-0,0501	0,0148			
	$N_t = (1 - \theta_2 B^2 - \theta_4 B^4) \cdot e_t$					
	θ_2	0,2033	0,1147			
	θ_4	-0,2390	0,1127			
H_T	CONST	4,0413	0,0204	41,8	0,140 E-01	-3,965
	WRHOM ₀	-0,0766	0,0134			
	ATLNAM ₀	-0,0632	0,0267			
	$N_t = (1 - \theta_2 B^2 - \theta_3 B^3) \cdot e_t$					
	θ_2	-0,2669	0,1134			
	θ_3	-0,1954	0,1138			
I_T	CONST	4,0443	0,0141	45,5	0,131 E-01	-3,971
	WRHOM ₀	-0,0660	0,0141			
	STHIND ₀	-0,0393	0,0164			
	ATLNAM ₀	-0,0349	0,0289			
	$N_t = 1/(1 - \phi_3 B^3 - \phi_4 B^4) \cdot e_t$					
	ϕ_3	0,2492	0,1180			
	ϕ_4	-0,2533	0,1204			
J_T	CONST	4,0503	0,0022	63,1	0,887 E-02	-4,300
	WRHOM ₀	-0,0729	0,0103			
	WRHOM ₇	-0,0461	0,0102			
	STHIND ₀	-0,0734	0,0081			
	$N_t = \frac{(1 - \theta_4 B^4 - \theta_5 B^5)}{(1 - \phi_1 B)} \cdot e_t$					
	θ_4	0,6182	0,1053			
	θ_5	0,3811	0,1077			
	ϕ_1	-0,2765	0,1195			

5.2.3 Remarques générales sur les résultats des modèles de FTB

Les tableaux 4.2, 5.1 et 5.2 résument les modèles ARMA et FTB construits pour la prévision de la crue du Nil. Les remarques suivantes s'en dégagent :

- ♦ L'inclusion des séries des TSO comme variables exogènes améliore significativement la capacité des modèles de Box et Jenkins d'expliquer la variabilité de la série d'ASSOUAN. Alors que le meilleur modèle ARMA (modèle C, tableau 4.2) explique seulement 6% de la variabilité du volume de la crue, le meilleur modèle de FTB (modèle J_7) explique 63% de cette variabilité. La variance des résidus du modèle J_7 est de 40% inférieure à celle du modèle C.
- ♦ La constante de la FTB regroupe toutes les constantes qui figurent dans l'équation 3.8. Elle est égale à la moyenne de la série d'ASSOUAN, car les moyennes des autres séries sont égales à zéro.
- ♦ Les estimations des paramètres au délai zéro associés aux séries *WRHOM* et *STHIND* varient peu, que ce soit dans un modèle de FTB à une seule variable exogène ou à plusieurs variables. Ces paramètres varient peu, même si on utilise des échantillons de 25 années pour les estimer. Le rapport de la différence entre l'estimation la plus et la moins élevée à la moyenne des estimés est moins que 20%.

$$\frac{\text{Estimation la plus élevée} - \text{Estimation la plus basse}}{\text{Moyenne des estimations}} < 0,20 \quad (5.10)$$

Quant aux paramètres associés à la série d'ATLNAM, ils sont très instables dans le temps et peuvent changer de signe dépendant de la période d'années utilisée pour leur estimation.

- ♦ Les résultats obtenus sont meilleurs que ceux de Seleshi (1997) qui a utilisé un modèle de FTB pour prédire les anomalies de précipitations sur le HPE avec 5 variables exogènes et 15 paramètres à estimer. Le modèle de FTB présenté ci-dessus

est plus parcimonieux (7 paramètres seulement à estimer), et plus vraisemblable du point de vue des téléconnexions exploitées pour fins de prévision (cf. section 5.5).

Après avoir présenté les différents modèles FTB et vérifié approximativement la stabilité temporelle des estimations des paramètres, la performance des modèles en prévision est discutée dans la prochaine section.

5.2.4 Performance des modèles FTB en prévision

Tout d'abord, une distinction est nécessaire entre "les valeurs ajustées" de la série de sortie et "les valeurs prédites". Les premières désignent les prévisions à un pas de temps de la série de sortie produites en utilisant un modèle dont les paramètres sont estimés sur la même période de temps de prévision (ici de 1920 à 1969). Quant aux valeurs prédites, elles réfèrent aux prévisions à un pas de temps avec un modèle où seules les données des années passées ont été utilisées pour l'estimation des paramètres. Par exemple, pour prédire la valeur de la série d'*ASSOUAN* en 1970, le modèle FTB est ajusté aux données utilisées de 1920 à 1969. Pour prédire la valeur de 1971, les données utilisées dans l'estimation des paramètres du modèle vont de 1920 à 1970, et ainsi de suite. La prévision à un pas de temps est faite trois mois à l'avance, i.e. les entrées utilisées sont les données de TSO de juin de l'année courante pour prédire le volume de la crue du Nil qui possède sa pointe en septembre. Cette approche a l'avantage d'utiliser les valeurs actuelles des TSO et ainsi éliminer l'erreur et l'incertitude associées à la prévision des entrées. D'autres études ont utilisé une prévision des TSO pour étendre l'horizon de prévision (Eltahir, 1996; Amarasekera *et al.*, 1997).

Quatre indices sont utilisés pour évaluer la performance en prévision des modèles déjà présentés :

r est le coefficient de corrélation entre les valeurs observées Y_i et les valeurs prédites $\hat{Y}_i$,

$REQM$ est la racine carrée de l'erreur quadratique moyenne des prévisions

$$REQM = \sqrt{\sum_{i=1}^{n_f} (Y_i - \hat{Y}_i)^2 / n_f} \quad (5.11)$$

MDA est la moyenne des différences absolues entre Y_i et $\hat{Y}_i$

$$MDA = \sum_{i=1}^{n_f} |Y_i - \hat{Y}_i| / n_f \quad (5.12)$$

$MPEA$ est la moyenne des pourcentages des erreurs absolues calculée comme

$$MPEA = \sum_{i=1}^{n_f} \frac{|Y_i - \hat{Y}_i|}{Y_i} \times \frac{100}{n_f} \quad (5.13)$$

où n_f est le nombre des valeurs prédites.

Les valeurs ajustées des modèles D_{T2} , E_T , F_{T3} , G_T et J_T pour la période de 1920 à 1969 sont illustrées aux figures 5.8 de (a) à (e). Les valeurs prédites utilisant les mêmes modèles sont illustrées aux figures 5.9 de (a) à (e) pour la période de 1970 à 1989. La figure 5.8 montre que le modèle J_T est nettement supérieur aux modèles D_{T2} , E_T , F_{T3} . Le modèle J_T prédit aussi bien les crues abondantes (1929 – 1945 – 1954 – 1964) que déficientes (1939 à 1941 – 1951 – 1965 – 1966 – 1968), avec quelques exceptions durant les années 1938, 1948, 1949, 1958 et 1961. Les raisons de ces mauvaises prévisions sont discutées à la section 5.5.

La figure 5.9 montre des résultats similaires avec de bonnes prévisions obtenues par le modèle J_T dans toutes les années utilisées pour le test sauf l'année 1984. Cette mauvaise prévision est aussi commentée à la section 5.5. Il est à noter ici que le meilleur modèle J_T est capable de prédire avec précision la plupart des crues détectées comme valeurs aberrantes (cf. section 4.1) comme 1945, 1972 et 1988.




Figure 5. 8 : Volumes de la crue d'été à Assouan **ajustés** en utilisant les modèles de FTB : (a) D_{T2} , (b) E_T , (c) F_{T3} , (d) G_T , et (e) J_T




Figure 5. 8 (suite) : Volumes de la crue d'été à Assouan ajustés en utilisant les modèles de FTB : (a) D_{T2} , (b) E_T , (c) F_{T3} , (d) G_T , et (e) J_T

Les quatre indices de performance en prévision cités précédemment sont calculés pour les six modèles D_{T2} , E_T , F_{T3} , G_T , H_T et J_T sur deux ensembles de données qui ne sont pas utilisés pour l'estimation des paramètres des modèles. Le premier ensemble test couvre la période de 1970 à 1989, alors que le deuxième ensemble test couvre la même période sans l'année 1984. Les résultats des quatre indices de performance sont présentés au tableau 5.3.




Figure 5. 9 : Volumes de la crue d'été à Assouan **prédits** en utilisant les modèles de FTB : (a) D_{T2} , (b) E_T , (c) F_{T3} , (d) G_T , et (e) J_T




Figure 5.9 (suite) : Volumes de la crue d'été à Assouan **prédits** en utilisant les modèles de FTB : (a) D_{T2} , (b) E_T , (c) F_{T3} , (d) G_T , et (e) J_T

Le meilleur modèle (J_T), ayant le plus bas CIB , est nettement supérieur pour tous les indices de performance sans ou avec l'année 1984. Une analyse plus poussée permet de détecter 1984 comme une valeur aberrante, mais il faut interpréter avec précaution cette conclusion d'aberrance vu que l'année 1984 est vers l'extrémité de la série (Liu *et al.*, 1994). Le volume de la crue du Nil observé en 1984 est illustré par un cercle noir sur la figure 5.9.

Tableau 5.3 : Performances en prévision des modèles D_{T2} , E_T , F_{T3} , G_T , H_T et J_T

Modèle	1970 à 1989				1970 à 1989 excluant 1984			
	r	$REQM$	MDA	$MPEA$	r	$REQM$	MDA	$MPEA$
J_T	0,827	6,241	4,379	9,434	0,916	3,889	3,287	6,092
H_T	0,679	8,077	5,682	11,815	0,799	5,830	4,432	7,987
G_T	0,711	7,933	5,761	12,243	0,845	5,490	4,448	8,221
F_{T3}	0,488	9,895	7,797	15,788	0,465	8,615	6,709	12,455
E_T	0,273	10,203	7,022	13,908	0,363	8,870	5,894	10,457
D_{T2}	0,701	8,701	6,594	14,231	0,827	6,110	5,209	9,990

5.2.5 Test de comparaison entre les prévisions des différents modèles

Pour tester si les prévisions obtenues par un modèle sont significativement différentes de celles obtenues par un autre modèle, plusieurs tests sont disponibles, tel que le test du quotient de vraisemblance (Rao, 1973) et les tests non paramétriques comme celui de Wilcoxon (Wilcoxon, 1945). Ces tests donnent presque les mêmes résultats. C'est pourquoi Hipel et McLeod (1994) ont recommandé d'utiliser le test de Pitman (Pitman, 1939), équivalent au test du quotient de vraisemblance, parce qu'il demande moins de calculs que ce dernier. Le test de Pitman consiste à vérifier si la variance des erreurs de prévision produites par un modèle est significativement différente de celle d'un autre. Il revient à tester si le coefficient de corrélation r , entre S_t (la somme des erreurs de prévision des deux modèles comparés, i.e. $S_t = e_{1,t} + e_{2,t}$) et D_t (la différence entre les erreurs de prévision des mêmes deux modèles comparés, i.e. $D_t = e_{1,t} - e_{2,t}$) est significativement différent de zéro. À condition que le nombre (n_f) de valeurs prédites utilisées pour le test dépasse 25 ($n_f > 25$), les deux modèles de prévisions comparés sont considérés significativement différents au niveau de 95% si

$$|r| > \frac{1,96}{\sqrt{n_f}} \quad (5.14)$$

Le test de Pitman a pour but de comparer les modèles deux à deux. Ainsi le modèle D_{T1} est comparé aux huit autres modèles proposés (D_{T2} , E_T , F_{T1} , F_{T2} , F_{T3} , G_T , H_T , J_T), le modèle D_{T2} est comparé aux sept modèles restants (E_T , F_{T1} , F_{T2} , F_{T3} , G_T , H_T , J_T) et ainsi de suite, jusqu'à ce que toutes les comparaisons soient terminées. Pour ce faire, vingt cinq valeurs sont prédites à l'aide de chacun des modèles. Pour comparer les deux modèles D_{T1} et D_{T2} par exemple, le coefficient de corrélation r , présenté au paragraphe précédent, est calculé utilisant les deux séries des 25 prévisions faites à l'aide des deux modèles. Le tableau 5.4 montre les valeurs calculées du r de Pitman. Pour $n_f=25$, la différence dans l'erreur quadratique moyenne de prévision de deux modèles est significative au niveau de 95%, si $|r| > 0,392$. Si $r < -0,392$, le premier modèle (D_{T1} pour cette comparaison spécifique) est meilleur et si $r > 0,392$ le deuxième modèle (D_{T2}) est meilleur.

Les résultats des tests de Pitman sont tabulés (tableau 5.4) avec 36 comparaisons entre les neuf modèles proposés. Les modèles sont comparés deux à deux : le premier est situé sur une ligne et le second sur une colonne. Les résultats confirment que les modèles G_T et J_T sont, dans tous les tests de Pitman, significativement meilleurs ou équivalents aux autres modèles. Les modèles G_T et J_T , par contre, ne sont pas significativement différents. Néanmoins, puisque le modèle J_T a le plus petit REQM, MPAE et MDA de prévisions (tableau 5.3) et en plus est favori selon le CIB et R^2 (tableau 5.2), il est le modèle recommandé, parmi les neuf modèles de FTB, pour la prévision de la crue du Nil utilisant les TSO comme variables exogènes.

Tableau 5. 4 : Résultats de la comparaison par paires de modèles entre les neuf modèles de FTB proposés, utilisant le test de Pitman

Modèle	Modèle							
	D_{T2}	E_T	F_{T1}	F_{T2}	F_{T3}	G_T	H_T	J_T
D_{T1}	0,31 (=)	-0,16 (=)	-0,20 (=)	-0,37 (=)	-0,32 (=)	0,48 (+)	0,05 (=)	0,61 (+)
D_{T2}		-0,41 (-)	-0,46 (-)	-0,45 (-)	-0,40 (-)	0,20 (=)	-0,02 (=)	0,49 (+)
E_T			-0,08 (=)	0,15(=)	0,18 (=)	0,69 (+)	0,52 (+)	0,65 (+)
F_{T1}				0,40 (+)	0,40 (+)	0,68 (+)	0,58 (+)	0,67 (+)
F_{T2}					0,11 (=)	0,56 (+)	0,39 (=)	0,61 (+)
F_{T3}						0,51 (+)	0,39 (=)	0,59 (+)
G_T							0,27 (=)	0,30 (=)
H_T								0,42 (+)

(=) : la différence entre les prévisions des 2 modèles comparés n'est pas significative,

(-) : le modèle de la ligne est meilleur que celui de la colonne,

(+) : le modèle de la colonne est meilleur que celui de la ligne.

Les valeurs de corrélation significatives au niveau de 95% sont indiquées en gras.

5.3 Modèles de réseaux de neurones artificiels

L'application des réseaux de neurones artificiels (RNA) proposée dans ce travail de recherche présente deux aspects innovateurs dans les applications des RNA en hydrologie : le premier se rapporte aux variables exogènes utilisées et à l'horizon de prévision du modèle de RNA, le second aspect se rapporte à l'approche plus complète de l'application des RNA en hydrologie.

Pour ce qui est des variables exogènes, aucune des applications publiées dans la littérature n'a utilisé les RNA pour prédire directement les débits à l'aide des TSO comme variables exogènes. Les RNA sont généralement appliqués pour la prévision à très court terme (moins que sept jours), tandis que les modèles de RNA proposés dans cette thèse sont conçus pour la prévision à moyen terme (3 mois à l'avance). De plus, l'implémentation proposée des RNA accorde une attention particulière à la validation des modèles et à la quantification de l'incertitude par une technique de bootstrap. Par la suite, les résultats obtenus par les RNA sont comparés avec ceux obtenus par les FTB déjà présentées. La comparaison, présentée dans ce travail, n'est pas aussi extensive que celle de Michie *et al.* (1994), car elle ne traite que de deux types de données : les débits et les TSO. La comparaison de Michie *et al.* (1994) porte surtout sur les modèles de classification et non les modèles de prévision.

La construction des modèles de RNA, présentée dans ce chapitre, suit les étapes décrites au chapitre 3. De la même façon que pour la construction des modèles de FTB, des modèles de RNA à une variable exogène de TSO (section 5.3.1), puis des modèles à plusieurs variables exogènes (section 5.3.2) sont proposés. Comme la relation entre les entrées (TSO) et la sortie (crue du Nil) possède un coefficient de corrélation qui ne dépasse pas 0,6 (cf. section 4.4), les RNA auraient tendance à modéliser aussi le bruit. C'est pourquoi, dans la construction des RNA, il faut éviter le surapprentissage.

Deux mesures de précaution sont utilisées à cette fin :

- avoir la structure la plus simple du RNA : utiliser des modèles avec un ou deux neurones seulement sur la couche cachée.
- utiliser une technique d'arrêt prématuré : essayer plusieurs nombres d'itérations et retenir celui qui donne la plus petite erreur de généralisation telle que calculée par validation croisée. Cette méthode évite les lacunes de la division de l'échantillon

utilisée d'habitude avec l'arrêt prématuré, mais elle nécessite beaucoup de temps de calcul et elle ne donne pas la valeur optimale d'arrêt tout de suite.

Les modèles de RNA construits dans ce travail de recherche sont du genre *autorégressif neuronal avec variables exogènes (NNARX)* (équation 3.50). L'utilisation du modèle genre *autorégressif neuronal à moyenne mobile avec variables exogènes (NNARMAX)* (équation 3.51) a donné, pour certaines années, des sorties dix fois plus grandes que les valeurs observées. Nørgaard (1997) a mentionné que les NNARMAX sont souvent instables et a recommandé l'utilisation des modèles NNARX à chaque fois que cela est possible. Les FAC des résidus des modèles NNARX utilisés sont testés pour vérifier, si on n'a pas besoin d'incorporer une composante de moyenne mobile.

Le nombre p de composantes de délai de la série de sortie à incorporer comme entrées au RNA est déterminé par essais et erreurs. Ce nombre est équivalent à l'ordre (p) de l'opérateur autorégressif dans les FTB. Au début, p est égal à quatre (c'est le chiffre qui se répète le plus dans les modèles de FTB). Ensuite, les poids associés à ces quatre composantes de délai sont comparés entre eux. Les poids, relativement petits, sont éliminés avec les composantes de délai correspondantes, donnant ainsi un modèle plus parcimonieux. Les sorties des modèles avant et après la suppression des poids sont aussi comparées. Si le modèle réduit a la même performance que le modèle de départ, c'est le modèle réduit qui est choisi. Faute de tests statistiques sur la signifiante des paramètres d'un RNA, cette manière de procéder permet d'arriver à un modèle performant et parcimonieux.

La validation des modèles suit la méthodologie décrite à la section 3.3.6 utilisant les FCC entre les séries de variables exogènes et les résidus du modèle (équation 3.59), la FAC des résidus (section 3.2.3) et les FCC d'ordre plus élevé décrites par les équations 3.58 et 3.60 à 3.65.

Le meilleur modèle pour prédire la crue du Nil est choisi selon trois mesures de l'erreur de généralisation : le coefficient d'information bayésien (*CIB*), l'estimation de la variance du bruit calculée par validation croisée et celle calculée par la formule suivante de l'estimation non biaisée de la variance, utilisée dans les modèles linéaires :

$$\sigma_e^2 = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n - m_p} \quad (5.14)$$

La performance des modèles en prévision est testée sur deux échantillons qui n'ont pas été utilisés pour l'apprentissage des RNA, comme déjà présenté à la section 5.2.4, et les prévisions produites par les différents modèles proposés sont comparées à l'aide du test de Pitman (cf. section 5.2.5) et du test non paramétrique de Wilcoxon (Wilcoxon, 1945).

5.3.1 Modèles de RNA avec une seule variable exogène de TSO

Les mêmes variables exogènes utilisées dans les modèles de FTB, et qui ont été choisies selon les diagnostics climatologiques (cf. section 2.6) et les analyses de causalité (cf. section 4.4), sont incorporées dans les modèles de RNA. Trois modèles de RNA à une variable exogène de TSO sont donc développés, chacun avec une des trois variables exogènes retenues et des composantes de délai de la série de sortie :

Modèle D_N :

$$ASSOUAN = f(WRHOM, ASSOUAN) \quad (5.15)$$

Modèle E_N :

$$ASSOUAN = f(STHIND, ASSOUAN) \quad (5.16)$$

Modèle F_N :

$$ASSOUAN = f(ATLNAM, ASSOUAN) \quad (5.17)$$

Les figures de 5.10 à 5.12 illustrent les six FCC utilisées pour chaque figure afin de vérifier l'adéquation des modèles, selon la méthode proposée par Billings et Zhu (1994) et utilisée par Nørgaard (1997). Comme déjà mentionné pour la validation des modèles de FTB, les poids positifs proches de zéro sont inspectés vu que la physique de la relation entre les TSO et la crue du Nil ne supporte pas l'hypothèse que les TSO soient influencées par la crue du Nil. Aucun poids significatif aux délais positifs proche de zéro n'est détecté dans les 18 FCC illustrées, sauf ceux au 3^{ième} délai de la FCC entre le carré de l'entrée et les résidus du modèle F_N et au 4^{ième} délai de la FCC entre le carré de l'entrée et le carré des résidus du même modèle F_N . Ces coefficients sont peu significatifs.

Il est à noter que le poids au délai zéro de la première figure est égal à un, vu que c'est l'autocorrélation d'une série avec elle-même (équation 3.65). Quant à la figure 5.13, elle illustre les FAC des trois modèles de RNA à variable exogène unique. Les poids des FAC ne dépassent pas la limite de confiance de 95%.




Figure 5. 10 : Fonctions de corrélation croisée pour valider le modèle D_N (X étant WRHOM, et $\alpha_i(t) = Y(t) \cdot e(t)$)




Figure 5. 11 : Fonctions de corrélation croisée pour valider le modèle E_N (X étant STHIND, et $\alpha_i(t) = Y(t) \cdot e(t)$)




Figure 5.12 : Fonctions de corrélation croisée pour valider le modèle F_N (X étant ATLNAM, et $\alpha_i(t) = Y(t) \cdot e(t)$)




Figure 5.13 : Fonction d'autocorrélation des résidus des modèles (a) D_N , (b) E_N et (c) F_N

Le tableau 5.5 montre une comparaison de ces trois modèles selon la variance du bruit estimée par validation croisée, le coefficient de détermination ajusté et le critère d'information bayésien (CIB) de chaque modèle. Comme déjà cité dans les propriétés des RNA, un même ensemble d'entrées et de sorties peut aboutir à des ensembles de paramètres très différents à chaque fois que le RNA est entraîné. Il est donc sans intérêt

de présenter les paramètres des RNA, d'autant plus que leur signification est masquée par la complexité du réseau et la non-linéarité des connexions.

Tableau 5. 5 : Comparaison entre les modèles de RNA à une variable exogène

Modèle	Nombre de paramètres	σ_e^2 estimée par $\sigma_e^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 / (n - m_p)$	σ_e^2 estimée par validation croisée	<i>CIB</i>
D_N	6	0,116 E-01	0,138 E-01	-3,9904
E_N	6	0,133 E-01	0,141 E-01	-3,8505
F_N	6	0,156 E-01	0,161 E-01	-3,6901

Le modèle D_N (avec WRHOM comme variable exogène) est le meilleur pour les trois critères déjà cités, ayant la plus petite variance du bruit et le plus petit *CIB*. On remarque aussi que l'estimation de σ_e^2 par validation croisée est plus grande pour les trois modèles. L'estimation non biaisée de la variance est plus optimiste. L'estimation de la variance par validation croisée introduit l'effet du ré-entraînement du RNA pour chaque échantillon de validation croisée.

5.3.2 Modèles de RNA à plusieurs variables exogènes de TSO

Comme dans le cas des modèles de FTB, trois modèles à plusieurs variables exogènes sont construits. La variable WRHOM est utilisée dans chacun des trois modèles. La variable STHIND est introduite au modèle G_N , la variable ATLNAM au modèle H_N et ensuite les deux variables ensemble au modèle I_N .

Modèle G_N :

$$ASSOUAN = f(WRHOM, STHIND, ASSOUAN) \quad (5.18)$$

Modèle H_N :

$$ASSOUAN = f(WRHOM, ATLNAM, ASSOUAN) \quad (5.19)$$

Modèle I_N :

$$ASSOUAN = f(WRHOM, STHIND, ATLNAM, ASSOUAN) \quad (5.20)$$

Les FCC d'ordre élevé pour les modèles G_N , H_N et I_N sont illustrées aux figures 5.14 a et b, 5.15 a et b et 5.16 a, b et c, respectivement. Seuls les poids positifs proches de zéro sont inspectés, vu que la physique de la relation entre les TSO et la crue du Nil ne peut pas être un système à feed-back. Des poids significatifs sont détectés à deux délais : au 2^{ième} délai de la FCC entre le carré de la série WRHOM et le carré des résidus pour les modèles G_N , H_N et I_N , ainsi qu'au 3^{ième} délai de la FCC entre le carré de la série STHIND et les résidus des modèles G_N et I_N . Des composantes de délai de WRHOM et de STHIND sont incorporés, mais la performance des modèles n'est pas améliorée. Ces poids semblent d'ailleurs peu significatifs. Comme les poids des FCC au 7^{ième} délai associés à la série d'entrée WRHOM ne sont pas significatifs, il n'y a pas de raison de construire un modèle analogue au modèle J_T de FTB.




Figure 5. 14 : Fonctions de corrélation croisée pour valider le modèle G_N : (a) X étant WRHOM, (b) X étant STHIND et $\alpha_i(t) = Y(t) \cdot e(t)$




Figure 5. 14 (suite) : Fonctions de corrélation croisée pour valider le modèle G_N : (a) X étant WRHOM, (b) X étant STHIND et $\alpha_i(t) = Y(t) \cdot e(t)$




Figure 5. 15 : Fonctions de corrélation croisée pour valider le modèle H_N (a) X étant WRHOM, (b) X étant ATLNAM et $\alpha_i(t) = Y(t) \cdot e(t)$)




Figure 5.15 (suite) : Fonctions de corrélation croisée pour valider le modèle $H_N(a)$ X étant WRHOM, (b) X étant ATLNAM et $\alpha_i(t) = Y(t) \cdot e(t)$




Figure 5. 16 : Fonctions de corrélation croisée pour valider le modèle $I_N(a)$ X étant WRHOM, (b) X étant STHIND, (c) X étant ATLNAM et $\alpha_i(t) = Y(t) \cdot e(t)$




Figure 5. 16 (suite) : Fonctions de corrélation croisée pour valider le modèle $I_N(a) X$ étant WRHOM, (b) X étant STHIND, (c) X étant ATLNAM et $\alpha_t(t) = Y(t) - e(t)$




Figure 5. 16 (suite) : Fonctions de corrélation croisée pour valider le modèle $I_N(a)$ X étant WRHOM, (b) X étant STHIND, (c) X étant ATLNAM et $\alpha_i(t) = Y(t) \cdot e(t)$

Les FAC des résidus (figure 5.17) indiquent que ceux-ci sont blancs. Le tableau 5.6 présente une comparaison entre les différents modèles de RNA à plusieurs variables exogènes de TSO selon le nombre de paramètres utilisés, la variance du bruit et le *CIB*. En fonction des trois critères, le modèle G_N est le meilleur.




Figure 5. 17 : Fonction d'autocorrélation des résidus des modèles (a) G_N , (b) H_N et (c) I_N

Tableau 5. 6 : Comparaison entre les modèles de RNA à plusieurs variables exogènes

Modèle	Nombre de paramètres	σ_e^2 estimée par $\sigma_e^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 / (n - m_p)$	σ_e^2 estimée par validation croisée	CIB
G_N	7	0,104 E-01	0,119 E-01	-3,9915
H_N	7	0,117 E-01	0,140 E-01	-3,8972
I_N	8	0,109 E-01	0,123 E-01	-3,8902

5.3.3 Performance des modèles de RNA en prévision

Les sorties d'un modèle de RNA, utilisant l'échantillon d'apprentissage, sont appelées les "valeurs ajustées", tandis que les sorties de ce même modèle, utilisant des échantillons appartenant à l'ensemble du test, sont appelées les "valeurs prédites". Les valeurs ajustées des modèles D_N , E_N , F_N , G_N , H_N et I_N pour la période de 1920 à 1969 sont illustrées aux figures 5.18 de (a) à (f). Les valeurs prédites utilisant les mêmes modèles sont présentées aux figures 5.19 de (a) à (f) pour la période de 1970 à 1989.

Comme pour le meilleur modèle de FTB, le meilleur modèle de RNA (G_N , figures 5.18 d et 5.19 d) a une haute capacité de prévision dans les années de fortes et de faibles crues. Pourtant, il prédit mal la crue du Nil pour les années : 1938, 1949, 1954, 1958, 1959, 1961 et 1984. Ces 7 années, sur un total de 70 années prédites, constituent un faible pourcentage d'échec du modèle. Ce sont presque les mêmes années où les modèles de FTB échouent, sauf que le meilleur modèle de FTB (J_7) prédit bien la crue de l'année 1954 mais mal celle de l'année 1948. Une interprétation climatologique de la mauvaise prévision des deux types de modèles est présentée à la section 5.5. Elle permet de connaître les limites des modèles reliant les TSO (Pacifique + océan Indien) aux crues du Nil.




Figure 5. 18 : Volumes de la crue d'été **ajustés** utilisant les modèles de RNA : (a) D_N

(b) E_N (c) F_N (d) G_N (e) H_N et (f) I_N .




Figure 5. 18 (suite) : Volumes de la crue d'été **ajustés** utilisant les modèles de RNA :

(a) D_N (b) E_N (c) F_N (d) G_N (e) H_N et (f) I_N






Figure 5. 19 : Volumes de la crue d'été **prédits**, utilisant les RNA, pour les modèles : (a)

D_N (b) E_N (c) F_N (d) G_N (e) H_N et (f) I_N .

(d)



(e)



(f)





Figure 5. 19 (suite) : Volumes de la crue d'été prédits, utilisant les RNA, pour les modèles : (a) D_N (b) E_N (c) F_N (d) G_N (e) H_N et (f) I_N

Quatre indices de performance servent à évaluer la performance en prévision des RNA : le coefficient de corrélation entre les valeurs prédites et observées (r), la racine de l'erreur quadratique moyenne ($REQM$), la moyenne des différences absolues (MDA) et la moyenne du pourcentage des erreurs absolues ($MPEA$) comme pour les FTB (cf. section 5.2.4). Ils sont calculés pour les six modèles sur deux ensembles tests, comme pour les FTB, qui ne sont pas utilisés pour l'apprentissage des RNA. Rappelons que le premier ensemble de test couvre la période de 1970 à 1989, alors que le deuxième ensemble de test couvre la même période sans l'année 1984. Les quatre indices de performance sont présentés au tableau 5.7.

Tableau 5.7 : Performance en prévision des modèles D_N , E_N , F_N , G_N , H_N et J_N

Modèle	De 1970 à 1989				De 1970 à 1989 sans 1984			
	r	$REQM$	MDA	$MPEA$	r	$REQM$	MDA	$MPEA$
I_N	0,770	6,836	4,695	9,863	0,879	4,535	3,551	6,361
H_N	0,767	8,467	6,607	14,037	0,865	6,059	5,284	9,987
G_N	0,772	6,803	4,690	9,793	0,890	4,536	3,556	6,323
F_N	0,290	10,358	7,854	15,771	0,273	9,078	6,739	12,357
E_N	0,366	9,907	6,795	13,275	0,477	8,537	5,671	9,833
D_N	0,761	8,597	6,594	14,174	0,868	5,318	4,461	8,422

Un meilleur modèle aurait un coefficient de corrélation plus élevé et des $REQM$, MDA et $MPEA$ plus petits. En fait, le $REQM$ et le $MPEA$ sont les plus importants, car le premier reflète l'importance des grandes erreurs et le second a un attrait opérationnel, vu qu'une erreur de $5 \times 10^6 \text{ m}^3$ ne peut être vraiment jugée qu'en sachant l'ordre de grandeur de la valeur prédite. Le meilleur modèle est donc le modèle G_N , mais le

modèle I_N est très voisin de ce dernier, car l'introduction des TSO de l'Atlantique à ce modèle n'améliore pas sa performance. Ceci a été remarqué dans les modèles de FTB par la non-signification du paramètre associé à la série ATLNAM.

5.3.4 Test de comparaison entre les prévisions des différents modèles

Bien que les mesures de performance du tableau 5.8 permettent une bonne comparaison entre les modèles, elles ne fournissent pas une indication pour montrer si un modèle particulier est significativement "meilleur" qu'un autre d'un point de vue statistique. Le test de Pitman a été présenté à la section 5.2.5. Il fait deux hypothèses : (i) les paires de résidus $(e_{1,t}, e_{2,t})$ suivent conjointement une distribution normale de moyenne égale à zéro, (ii) les résidus sont indépendants pour des valeurs successives de t , i.e. leurs poids de la FAC ne sont pas significatifs. La deuxième hypothèse du test a déjà été vérifiée, et les moyennes des séries des résidus ne sont pas différentes de zéro au niveau de confiance de 95%. Le test de Shapiro-Wilk indique, à un niveau de confiance de 95%, que les résidus de RNA suivent une distribution normale. Cette hypothèse, loin d'être explicite dans les modèles de RNA (cf. section 3.3.2), est nécessaire pour pouvoir utiliser le test de Pitman. Les résultats du test de Pitman sont présentés au tableau 5.8. Ils indiquent que les modèles D_N , G_N , H_N , et I_N sont équivalents de point de vue de la différence entre leurs prévisions. Rappelons que le même test de Pitman, utilisé pour tester la signification de la différence entre la variance des résidus des deux modèles (D_T et G_T) de FTB a confirmé que le modèle G_T est meilleur.

Le test non paramétrique des rangs signés de Wilcoxon (Wilcoxon, 1945) est aussi utilisé pour tester la différence entre les modèles D_N , G_N , H_N , et I_N . Le test de Wilcoxon teste la signification de la différence absolue entre les carrés des résidus :

$$|D_i| = |e_{i,1}^2 - e_{i,2}^2| \quad (5.21)$$

Tableau 5. 8 : Résultats de la comparaison par paires de modèles entre les six modèles de RNA proposés, utilisant le test de Pitman

Modèle	Modèle					
	D_N	E_N	F_N	G_N	H_N	I_N
D_N	—	-0,60 (-)	-0,63 (-)	0,05 (=)	-0,08 (=)	0,05 (=)
E_N		—	-0,03 (=)	0,72 (+)	0,46 (+)	0,71 (+)
F_N			—	0,66 (+)	0,49 (+)	0,65 (+)
G_N				—	-0,10 (=)	0,06 (=)
H_N					—	0,10 (=)
I_N						—

(=) : la différence entre les prévisions des modèles comparés n'est pas significative,

(-) : le modèle de la ligne est meilleur que celui de la colonne,

(+) : le modèle de la colonne est meilleur que celui de la ligne.

Les valeurs de corrélation significatives au niveau de 95% sont indiquées en gras.

Il ne pose pas l'hypothèse de normalité des résidus, mais fait les hypothèses suivantes :

- la distribution de la différence absolue $|D_i|$ est symétrique,
- les différences $|D_i|$ sont mutuellement indépendantes,
- les $|D_i|$ possèdent la même médiane, et
- la population des $|D_i|$ est continue.

Les résultats du test de Wilcoxon sont identiques à ceux du test de Pitman mis à part que le test de Wilcoxon indique que le modèle G_N est meilleur que celui de D_N au niveau de signification de 95%. Pour calculer la statistique du test de Wilcoxon, le rang des $|D_i|$ est multiplié par le signe de D_i . Le modèle G_N a des erreurs de moindre

amplitude que celle de D_N , ce qui explique la différence des conclusions des tests de Pitman et de Wilcoxon. Néanmoins, si les hypothèses d'un test paramétrique sont respectées, celui-ci est plus performant que les tests non paramétriques.

5.4 Comparaison entre les modèles de FTB et de RNA

Les figures 5.20 de (a) à (f) illustrent les prévisions produites par le modèles de FTB et de RNA du genre D , E , F , G , H et I , respectivement. Elles proviennent des figures déjà présentées (figures 5.9 et 5.19). Le tableau 5.9 récapitule les indices de performance de tous les modèles qui ont été déjà présentés aux tableaux 5.3 et 5.7.

Tableau 5. 9 : Tableau récapitulatif des indices de performance des modèles de FTB et de RNA

Modèle	1970 à 1989				1970 à 1989 excluant 1984			
	r	$REQM$	MDA	$MPEA$	r	$REQM$	MDA	$MPEA$
J_T	0,827	6,241	4,379	9,434	0,916	3,889	3,287	6,092
H_T	0,679	8,077	5,682	11,815	0,799	5,830	4,432	7,987
G_T	0,745	7,372	5,140	10,981	0,869	5,084	3,946	7,326
F_{TI}	0,207	10,671	7,845	15,983	0,140	9,684	7,086	13,237
E_T	0,273	10,203	7,022	13,908	0,363	8,870	5,894	10,457
D_{TZ}	0,701	8,701	6,594	14,231	0,827	6,110	5,209	9,990
I_N	0,770	6,836	4,695	9,863	0,879	4,535	3,551	6,361
H_N	0,767	8,467	6,607	14,037	0,865	6,059	5,284	9,987
G_N	0,772	6,803	4,690	9,793	0,890	4,536	3,556	6,323
F_N	0,290	10,358	7,854	15,771	0,273	9,078	6,739	12,357
E_N	0,366	9,907	6,795	13,275	0,477	8,537	5,671	9,833
D_N	0,761	8,597	6,594	14,174	0,868	5,318	4,461	8,422






Figure 5. 20 : Comparaison entre les prévisions utilisant les modèles de FTB et de RNA pour le modèle de type (a) *D*, (b) *E*, (c) *F*, (d) *G*, (e) *H* et (f) *I*

(d)



(e)



(f)




Figure 5. 11 (suite) : Comparaison entre les prévisions utilisant les modèles de FTB et de RNA pour le modèle de type (a) *D*, (b) *E*, (c) *F*, (d) *G*, (e) *H* et (f) *I*

Les conclusions suivantes sont tirées du tableau 5.9 et de la figure 5.20 :

- ♦ Les prévisions par les modèles de FTB sont presque similaires à celles obtenues par les modèles de RNA. Cette similarité est due à deux facteurs :
 - l'hypothèse de linéarité de la relation entre les TSO choisies et la série d'ASSOUAN est une approximation acceptable. Ceci rejoint les conclusions de Bhatt (1989).
 - les RNA ont besoin de plus de 50 données pour détecter la présence d'une composante non linéaire entre la sortie et les entrées. Les modèles construits de RNA fonctionnent plus dans la portion quasi linéaire de la fonction d'activation sigmoïde. En fait, les RNA sont surtout utilisés en hydrologie pour modéliser la relation non linéaire entre les précipitations et le ruissellement et où les observations sont plus abondantes. Fortin *et al.* (1997), dans leur revue bibliographique des méthodes de prévision des débits, excluent les RNA dans les prévisions des débits saisonniers ou annuels faute de données. Cependant, cette présente recherche montre que les RNA permettent d'obtenir des prévisions précises, pourvu que les précautions pour éviter le surapprentissage déjà mentionnées au début de la section 5.3 soient intégrées.
- ♦ On remarque, quand même, que les modèles de RNA sont légèrement plus performants que leurs homologues de FTB, surtout sur l'ensemble des tests sans l'année 1984. L'année 1984 est un cas très différent de ce que les RNA ont connu dans l'ensemble d'apprentissage. Le seul modèle de FTB qui soit supérieur est le modèle J_T avec un paramètre additionnel au septième délai associé à la série WRHOM. Les prévisions de ce modèle sont plus précises grâce à la forme de l'équation de prévision par FTB (équation 3.25). L'opérateur autorégressif $\Phi(B)$, qui multiplie les fonctions d'impulsion-réponse, permet l'utilisation des valeurs des

séries de variables exogènes à plusieurs délais, sans pour autant augmenter le nombre de paramètres. C'est l'avantage des FTB sur les modèles ARMAX, que le NNARMAX généralise. Cependant, si les relations entre les entrées et les sorties ne toléraient pas une approximation linéaire, les RNA auraient été nettement supérieurs.

- ◆ Les *REQM* des modèles de FTB sont, en général, plus petits que ceux des modèles de RNA. Les prévisions par FTB sont conçues de manière à minimiser ce critère. Par contre, les *MPEA* des RNA sont, en général, plus petits que ceux de FTB. La transformation logarithmique de la sortie favorise les *MPEA* plus petits, car la différence entre deux logarithmes est équivalente à la différence entre les rapports des deux valeurs non transformées.
- ◆ La série de WRHOM semble dominer le comportement du RNA. L'ajout des autres variables exogènes n'améliore pas les indices de performance comme c'est le cas pour les modèles de FTB. Ceci provient du fait que le modèle D_N de RNA, avec WRHOM comme unique variable exogène, semble être plus performant que son homologue de FTB.
- ◆ La figure 5.21 illustre une comparaison entre les prévisions des modèles G_T , J_T et G_N . On remarque que le modèle G_N tend à avoir une prévision plus proche de J_T que de G_T .

En fait, la supériorité du modèle J_T par rapport au modèle G_N provient essentiellement de sa meilleure prévision de la crue de 1975. Si on enlève cette année de l'ensemble test, les résultats des indices de performance seraient pour le modèle J_T : $REQM=3,811$, $MDA=3,115$ et $MPEA=5,853$; et pour le modèle G_N , ils seraient : $REQM=3,910$, $MDA=3,042$ et $MPEA=5,608$.




Figure 5. 21 : Comparaison des prévisions utilisant les modèles de FTB G_T et J_T avec celles utilisant le modèle de RNA G_N

Le tableau suivant (tableau 5.10) illustre une comparaison entre les modèles, proposés dans la présente recherche, et ceux publiés dans la littérature. Ces modèles sont tous conçus pour prédire soit les précipitations sur le haut plateau éthiopien (HPE) ou bien les écoulements du Nil principal ou un de ses tributaires. Le tableau démontre sans équivoque que les modèles (en gras), proposés par la présente recherche, ont une performance supérieure aux autres modèles publiés. Le modèle J_T est légèrement supérieur à celui de Seleshi (1997), tout en étant plus parcimonieux et plus vraisemblable du point de vue des téléconnexions exploitées pour fins de prévision.

Tableau 5. 10 : Comparaison entre les modèles de la présente recherche et ceux publiés dans la littérature

Modèle	Type	Variable à prédire	Variables explicatives	Résultats
Amarese-kera et al. (1997)	Régr.	Écoul. Nil princip. Écoul. Nil Bleu Écoul. Atbara	Indice de TSO Indice de TSO Indice de TSO	r entre -,27 et -,44 r entre -,32 et -,47 r entre -,37 et -,44
Camberlin (1997)	Régr.	Précip. HPE	- Indice de pression - Pression à Darwin	R^2 de 36%
Eltahir (1996)	Régr.	Écoul. Nil princip.	Indice de TSO	R^2 de 25%
Lin (1995c)	Régr.	Précip. HPE	Indice de TSO	R^2 de 36%
Seleshi (1993)	Régr.	Précip. HPE	Pression à Darwin	R^2 de 32 et 35%
Seleshi (1997)	FTB	Précip. HPE	- Indices de TSO au Pacifique, Atlantique et océan Indien - Pression à Darwin - Nbre. Taches solaires	R^2 de 63%
Modèle J_T	FTB	Écoul. d'été Nil princip.	Indices de TSO au Pacifique et océan Indien	r (observés et prédits) = 0,91
Modèle G_N	RNA	Écoul. d'été Nil princip.	Indices de TSO au Pacifique et océan Indien	r (observés et prédits) = 0,85

5.5 Discussion

L'analyse des prévisions calculées à l'aide des modèles de FTB et de RNA déjà mentionnées conduit aux remarques suivantes :

- ◆ Les résultats des modèles de FTB et de RNA sont similaires. Basé sur l'analyse présentée à la section précédente, on peut conclure que l'approximation linéaire de la relation entre les TSO à l'est du Pacifique et la crue du Nil est justifiée à un degré acceptable de précision.
- ◆ La série WRHOM, représentative de l'ENSO, est la meilleure variable explicative de la série d'ASSOUAN. Elle est utilisée dans les modèles de FTB et de RNA de type *D*, *G*, *H* et *I*. En comparant les modèles avec WRHOM et ceux sans WRHOM (modèles de type *E* et *F*), on remarque que l'incorporation du signal ENSO permet de suivre les fluctuations de la crue du Nil. On remarque aussi que cette série seule ne permet pas de prédire avec précision la crue du Nil. Cette remarque est en accord avec Eltahir (1996) et Amaresekera *et al.* (1997). La variabilité interannuelle des débits du Nil est donc plus étroitement liée à la circulation zonale (dite de Walker) comme celle de l'ENSO. Ceci rejoint les conclusions de Camberlin (1997). La circulation zonale est liée à la pénétration boréale de la ZCIT, qui fait partie de la circulation méridionale (dite de Hadley) (Hulme, 1994). Ce lien se fait via l'affaiblissement du jet tropical de l'est (JTE) aux hautes couches troposphériques. Un déplacement méridional de 200 km de la trace au sol de la surface de confluence de la ZCIT se traduit par un déficit des précipitations de plus de 400 mm/an (Hulme, 1988 ; Hastenrath, 1991).
- ◆ Le modèle de type *E*, qui a la série STHIND comme unique variable exogène, est visiblement moins habile dans la prévision que le modèle de type *D*. La série STHIND ne peut pas être utilisée comme valeur explicative unique de la série ASSOUAN. La même remarque s'applique à la série ATLNAM.

- Quand la série ATLNAM, qui est le meilleur prédicteur parmi les séries de TSO du sud de l'Atlantique, est incorporée aux modèles I_T ou I_N , elle n'améliore pas les prévisions produites par les modèles G_T et G_N (qui ont comme variables exogènes les séries WRHOM et STHIND).
- ◆ L'utilisation des deux prédicteurs WRHOM et STHIND ensemble, dans les modèles de type G , I et J , permet de suivre les fluctuations de la crue du Nil et aussi de prédire cette dernière avec précision. L'ajout de STHIND "raffine" la réponse des modèles avec WRHOM. Des recherches antérieures ont lié le forçage de l'ENSO au Pacifique est avec un jet tropical de l'est (JTE) moins rapide et moins étendu (au troposphère élevé, 200hPa) (Moron *et al.*, 1995; Trzaska *et al.*, 1996b). Quand les anomalies de TSO de l'océan Indien sont associées au forçage ENSO, l'Afrique de l'est expérimente des anomalies importantes au bas troposphère (850hPa). Ces anomalies se reflètent en un flux de vent d'ouest augmenté (au nord du 15^{ième} degré de latitude nord) et un flux de mousson affaibli, très marqué sur toute la région est africaine. Sans le forçage des TSO de l'océan Indien, les anomalies de vent et de mousson sont beaucoup moins importantes (Trzaska *et al.*, 1996a). Ces constatations rejoignent parfaitement le comportement des FTB déjà présentées.
- ◆ Les modèles de FTB et de RNA semblent prédire moins bien la crue du Nil quand les séries de WRHOM et STHIND ont des valeurs proches de zéro et la série d'ATLNAM a des valeurs élevées positives ou négatives. Ceci se produit aux années : 1938, 1949, 1958, 1959 et 1984. Les années 1958 et 1959 appartiennent en fait à l'ensemble des années signalées par Trzaska *et al.* (1996a) où l'ENSO et l'océan Indien ont des valeurs faibles et l'Atlantique montre un refroidissement. Les années avant 1950 sont peu étudiées en climatologie. La mauvaise prévision de la sécheresse de 1984, identifiée comme une valeur aberrante dans les modèles de FTB et qui tombe à l'extérieur des limites de confiance de la prévision des modèles de FTB et de RNA, est due elle aussi à une discordance entre l'ENSO et l'Atlantique.

Pour cette année, les TSO de la région du Pacifique montrent un événement faible de type La-Niña, qui devrait être associé à une crue du Nil au-dessus de la moyenne. Cependant, l'Atlantique sud montre un événement fort de type El-Niño. Ce réchauffement excessif de l'Atlantique a déclenché la sécheresse la plus forte sur tout le Sahel, la côte de Guinée aussi bien qu'en Afrique de l'est (Lamb et Pepler, 1991). L'accord entre les TSO de l'Atlantique et la phase "froide" de l'ENSO semble être nécessaire pour produire une crue abondante du Nil. Cette remarque appuie les hypothèses de Nicholson (1997) qui, étudiant la variabilité de la pluviométrie au Sahel, conclut que les TSO de l'Atlantique sud modulent le signal "froid" de l'ENSO. L'incorporation de ce comportement dans un modèle stochastique de prévision ou dans une règle de logique floue dans un RNA est une avenue de recherche intéressante. On remarque aussi que, pour les modèles de type F , le coefficient de corrélation r , calculé sur l'ensemble des années excluant 1984, est plus faible que le coefficient de corrélation calculé sur l'ensemble avec l'année 1984 (cf. tableau 5.7).

- ◆ La mauvaise prévision de la crue de l'année 1961 est due à un scénario différent : cette année a connu une hausse considérable du niveau du lac Victoria en été aux sources du Nil Blanc (Hydromet, 1984). Le ruissellement résultant a pu atteindre la station de jaugeage d'Assouan, malgré la présence des régions marécageuses (cf. section 2.3.2). Comme déjà expliqué au chapitre 4, les variations au Nil Blanc ne sont pas considérées dans les modèles étudiés, vu leur faible importance pour la détermination de la crue du Nil.

Chapitre VI

CONCLUSIONS GÉNÉRALES

ET

PERSPECTIVES DE RECHERCHE

Au cours de notre travail de recherche, nous avons mis au point deux modèles de prévision des débits, dont la source est les précipitations en régions tropicales. Le premier est basé sur les fonctions de transfert avec bruit (FTB) et le second est basé sur les réseaux de neurones artificiels (RNA). La sortie de l'un ou l'autre des modèles est le volume cumulatif des apports naturels qui entrent dans un grand réservoir, soit le Haut Barrage d'Assouan (HBA). Les entrées des modèles sont les températures de surface de l'océan (TSO) dans des régions déterminées ainsi que les volumes cumulatifs des apports naturels des années antérieures. Les deux modèles font leurs prévisions à la fin du mois de juin, trois mois avant l'occurrence de la pointe de la crue qui a lieu en septembre. Au début du mois de juillet, il n'existe pas assez d'informations dans les volumes de crue des années antérieures, ni dans les précipitations du mois de juin pour pouvoir prédire avec précision le volume cumulatif des mois de juillet à octobre (comme déjà démontré au chapitre IV). Voilà pourquoi nous avons eu recours à une information climatique, telle que les TSO.

Les résultats obtenus grâce aux modèles présentés dans cette thèse sont fort satisfaisants. Bien que l'utilisation des TSO ou d'autres indices climatiques, comme entrées des modèles de prévision des débits du Nil, ne soit pas récente (Walker et Bliss, 1932 ; Bliss, 1932), les résultats des modèles publiés dans la littérature indiquent que la variation des débits du Nil, expliquée par les indices climatiques, est entre 25 et 30%. Ceci est insuffisant pour bâtir un modèle fiable de prévision des débits. Les modèles, présentés dans cette thèse, révèlent des potentialités intéressantes. Ils parviennent à expliquer 63% de la variation des débits, avec des coefficients de corrélation qui

excèdent 0,85 entre les débits prédits et les débits observés et des erreurs relatives de 6% en moyenne. Comparée aux modèles de prévision déjà publiés et utilisés, cette performance élevée est due à deux aspects innovateurs de cette thèse. Le premier se rapporte à un meilleur choix des prédicteurs des volumes cumulatifs de la crue, basé sur les études récentes en climatologie. Le second se rapporte au choix des modèles plus appropriés à la problématique de prévision des débits en utilisant les prédicteurs climatiques comme entrées. Un important apport de notre thèse est également la comparaison entre les fonctions de transfert avec bruit (FTB) et les réseaux de neurones artificiels (RNA).

Choix des indices climatiques

Nos modèles de prévision tiennent une de leurs originalités dans l'utilisation de plusieurs indices climatiques comme entrées des modèles de prévision, tout en conservant une explication physique du lien entre les entrées et la sortie. En général, les études précédentes utilisaient uniquement un indice de l'ENSO (El-Niño / Southern Oscillation) comme seul prédicteur des débits du Nil. Elles attribuaient la variation non expliquée des débits du Nil à des facteurs locaux indépendants des indices climatiques. Les conclusions de notre recherche confirment que l'ajout d'un indice climatique relié à l'océan Indien, qui est la source majeure d'humidité pour le bassin du Nil, améliore considérablement les prévisions de nos modèles. La moyenne des TSO à une région de l'océan Indien à la trace au sol de l'origine du jet de Somali s'est avérée un bon prédicteur de la crue du Nil. Cet indice est une nouveauté pertinente de notre thèse. Il permet de raffiner les prévisions faites à l'aide d'un modèle où seul un indice de l'ENSO est utilisé comme variable exogène. Ces conclusions rejoignent les récentes découvertes en climatologie comme déjà présenté au chapitre V. Il est à noter que le choix des prédicteurs de TSO basé sur les études climatologiques est confirmé par une analyse de causalité statistique entre les prédicteurs et les débits du Nil.

D'autre part, la prévision saisonnière, pour laquelle nous avons opté, constitue un raffinement du modèle. Les recherches précédentes reliaient les indices de l'ENSO aux débits annuels du Nil. Ceci est en contradiction avec les découvertes climatologiques récentes qui démontrent la réponse contradictoire des débits annuels des deux tributaires majeurs du Nil au même forçage de l'ENSO. Les modèles, élaborés dans cette thèse, permettent de dissocier la contribution des deux sources du Nil par la prévision des débits de la saison de crue uniquement, ce qui représente une réponse cohérente au forçage de l'ENSO.

L'utilisation des études diagnostiques en climatologie a donc permis de construire des modèles de prévision qui sont supportés par la physique des phénomènes générateurs des crues du Nil, et par conséquent, les résultats de ces modèles sont fiables et permettent, à leur tour, de valider les études climatologiques.

Choix des modèles de prévision

Les modèles de fonctions de transfert avec bruit (FTB) et de réseaux de neurones artificiels (RNA) sont utilisés pour la première fois pour prévoir directement les débits à partir des indices climatiques. La performance de ces modèles en prévision est nettement supérieure à celle des modèles de régression linéaire. Les études, publiées dans la littérature, des téléconnexions entre les débits et les indices climatiques utilisaient en général des modèles de régression linéaire simple et multiple. Ces modèles ne permettent ni de modéliser parcimonieusement la structure dynamique de la relation entre les variables d'entrée et de sortie, ni de modéliser la structure d'autocorrélation du bruit par un modèle de type ARMA. Par contre, les fonctions de transfert avec bruit (FTB) permettent cela et les réseaux de neurones artificiels (RNA) sont une extension des fonctions de transfert en permettant une représentation non linéaire de la relation entre les entrées et la sortie.

Pour démontrer la nécessité de recourir à ces modèles plus complexes, un modèle de régression multiple est ajusté aux mêmes entrées et sortie (chapitre IV). La moyenne des erreurs relatives de prévision du meilleur modèle de régression est de 8,3% avec un coefficient de corrélation de 0,8 entre les débits prédits et ceux observés. Les meilleurs modèles de FTB et de RNA ont un coefficient de corrélation entre les débits prédits et ceux observés qui s'élèvent à 0,9 et une moyenne des erreurs relatives de prévision de 6% ; ceci constitue une amélioration importante de la fiabilité de nos modèles par rapport à celle obtenue par une régression linéaire. Rappelons que le pourcentage de la variance expliquée par les modèles publiés et utilisés reliant les indices climatiques à la crue du Nil ne dépasse pas 36%.

L'analyse des résultats, surtout pour les années où les modèles donnent de mauvaises prévisions, permet de comprendre la dynamique de l'interaction entre les TSO à différentes régions et son impact sur la crue du Nil. Dans les années où le signal de l'ENSO est faible ou dans la phase froide (i.e. un événement de type La-Niña) et en même temps que l'Atlantique sud est chaud, les modèles décrits dans cette thèse ne donnent pas de bonnes prévisions. Le nombre d'années où cela se produit (7 années seulement sur un total de 70 années disponibles) est relativement petit pour pouvoir construire un modèle statistique qui tient compte de cette discordance entre les différents océans.

En conclusion, les modèles de FTB et de RNA offrent un grand potentiel d'utilisation opérationnelle pour la prévision des apports naturels qui rentrent au réservoir du Haut Barrage d'Assouan, vu les résultats satisfaisants des modèles et la connaissance de leurs limites.

Comparaison entre les modèles de FTB et de RNA

La comparaison entre les modèles de FTB et de RNA permet de tirer les deux conclusions suivantes, qui s'appliquent à de nombreuses problématiques de prévision à moyen terme des débits de fleuves tropicaux :

- ♦ Les résultats des modèles de FTB et de RNA sont similaires. Basé sur l'analyse présentée au chapitre V, on peut conclure que la relation entre les TSO dans l'est du Pacifique et la crue du Nil peut être approchée par une relation linéaire à un degré acceptable de précision.
- ♦ Les modèles de FTB sont plus appropriés pour traiter le problème de la prévision des débits saisonniers à un horizon de trois mois, grâce à leur parcimonie, à l'existence de méthodes pour leur validation et surtout vu le nombre restreint de données qui désavantage la modélisation par RNA. Cela n'est vrai que si l'hypothèse de linéarité est acceptable.

Perspectives de recherche

Suite à notre travail, les perspectives de recherche se situent à deux niveaux :

- (i) introduire d'autres variables climatiques exogènes pour prendre en compte d'autres facteurs, et
- (ii) améliorer les modèles de prévision.

En ce qui concerne les variables climatiques à introduire, on pourrait utiliser l'analyse multivariée pour déterminer sur l'océan global les composantes principales reliées aux débits du Nil. On pourrait aussi introduire les prédicteurs de la mousson de l'Inde.

En ce qui concerne les modèles de prévision, une alternative au modèle de FTB serait d'utiliser les modèles ARMAX non linéaires et comparer leur performance aux

modèles de RNA. Une amélioration des RNA serait de construire un RNA où les neurones ne sont pas complètement connectés, avec une division entre les variables exogènes et les composantes de délai. Une amélioration prometteuse serait aussi d'utiliser les types de RNA avec des règles de logique floue (*Fuzzy Logic Neural Networks*) qui permettraient de modéliser la dépendance des débits du Nil au forçage de l'ENSO dans sa phase froide sur l'état de l'Atlantique sud.

La recherche en hydrologie globale et en hydro-climatologie ne fait que débiter. L'abondance des données par satellites permettra une couverture plus globale, indépendante du trafic maritime, une numérisation instantanée des données et par la suite, un accès quasi instantané à l'information. Cette extension des séries temporelles ajoutera de la robustesse aux modèles et éliminera les influences transitoires. D'autre part, les progrès en climatologie théorique et empirique ouvrent la voie vers une meilleure connaissance du système couplé océano-atmosphérique et surtout de sa composante hydrosphérique.

BIBLIOGRAPHIE

- Abu-Zeid, M.A., et Hefny, K. (1992). Water resources assessment and management in Egypt during conditions of stress. *WMO Bulletin*, 41, pp. 35-46.
- Afifi, A.A., et Azen, S.P. (1979). *Statistical analysis: a computer oriented approach*, Academic Press, 442 pp.
- Aguado, E. (1987). A time series analysis of the Nile River low-flows. *Ann. Ass. Amer. Geog.*, 72, pp. 109-119.
- Akaike, H. (1969). Fitting autoregressive model for prediction. *Annals of the Institute of Statistical Mathematics*, 21, pp. 243-247.
- Akaike, H. (1970a). Statistical predictor identification. *Annals of the Institute of Statistical Mathematics*, 22, pp. 203-217.
- Akaike, H. (1970b). A fundamental relation between predictor identification and power spectrum estimation. *Annals of the Institute of Statistical Mathematics*, 22, pp. 219-223.
- Akaike, H. (1973). Information theory and extension of the maximum likelihood principle. in *2nd International Symposium on Information Theory*, Petrov, B. N., et Csaki, F., eds., Akadémiai Kiado, Budapest, pp. 267-281.
- Akaike, H. (1974). Markovian representation of stochastic processes and its application to the analysis of autoregressive moving average processes. *Annals of the Institute of Statistical Mathematics*, 26, pp. 363-387.
- Alexander, R.C., et Mobley, R.L. (1976). Monthly average sea-surface temperatures and icepack limits on a 1° global grid. *Monthly Weather Review*, 104, pp. 143-148.

- Amarasekera, K.N., Lee, R.F., Williams, E.R., et Eltahir, E.A.B. (1997). ENSO and the natural variability in the flow of tropical rivers. *Journal of Hydrology*, 200(1), pp. 24-39.
- Anderson, R.Y. (1992). Long-term changes in the frequency of occurrence of El-Niño events. in *El-Niño: Historical and paleoclimatic aspects of the Southern Oscillation*, Diaz, H. F., et Markgraf, V., eds., Cambridge University Press, pp. 193-200.
- Anmala, J., Nedunuri, K.V., Govindaraju, R.S., et Koelliker, J.K. (1995). Neural networks for prediction of watershed runoff. in *Proceedings of the Watershed Management Symposium*, San Antonio, TX, USA, 14-16 August 1995, ASCE, NY., pp. 348-356.
- Anselmo, V., Melone, F., et Ubertini, L. (1982). Application of multiple stochastic models to rainfall-flow relationship of the Toce River. in *Pre-Symposium Proceedings - International Symposium on Rainfall-Runoff Modeling*, Mississippi State, MS, Water Resour Publ., Littleton, Colo, USA, pp. 263-272.
- Anselmo, V., et Ubertini, L. (1979). Transfer function-noise model applied to flow forecasting. *Hydrological Sciences Bulletin*, 24(3), pp. 353-359.
- Atiya, A., El-Shoura, S., Shaheen, S., et El-Sherif, M. (1997). Application of neural networks to the problem of forecasting the flow of the river Nile. in *Workshop Proceedings of the 1997 7th IEEE Workshop on Neural Networks for Signal Processing, NNSP'97*, Amelia Island, FL, USA, 24-26 September 1997, IEEE, pp. 598-606.
- Attia, B.B., et Abulhoda, A. (1990). The ENSO phenomenon and its impact on river Nile hydrology. in *International Seminar on Climatic Fluctuations and Water Resources*, Abu-Zeid, M. A., et Biswas, A. K., eds., Cairo, 11-14 december 1989, pp. 71-79.

- Azoff, E.M. (1994). *Neural networks time series forecasting of financial markets*, Wiley, N.Y., 196 pp.
- Balek, J. (1977). *Hydrology and water resources in tropical Africa*, Elsevier, Amsterdam, 271 pp.
- Baracos, P.C., Hipel, K.W., et McLeod, A.I. (1981). Modeling hydrologic time series from the arctic. *Water Resources Bulletin*, 17(3), pp. 414-422.
- Barnett, T.P. (1991). The interaction of multiple time scales in the tropical climate system. *Journal of Climate*, 4, pp. 269-285.
- Barrett, C.B. (1993). The development of the Nile hydrometeorological forecast system. *Water Resources Bulletin*, 29, pp. 933-938.
- Bartlett, M.S. (1966). *An introduction to stochastic processes, with special reference to methods and applications*, Cambridge University Press, Cambridge, UK, 362 pp.
- Basheer, I.A., Reddi, L.N., et Najjar, Y.M. (1996). Site characterization by neuronets: an application to the landfill siting problem. *Ground Water*, 34(4), pp. 610-617.
- Baxt, W.G., et White, H. (1995). Bootstrapping confidence intervals for clinical input variable effects in a network trained to identify the presence of acute myocardial infarction. *Neural Computation*, 7, pp. 624-638.
- Beguin, J.M., Gourioux, C., et Monfort, A. (1980). Identification of a mixed autoregressive-moving average process: the Corner method. in *Time Series*, Anderson, O. D., ed., North Holland, Amsterdam, pp. 423-436.
- Bell, B. (1970). The oldest records of the Nile floods. *Geographical Journal*, 136, pp. 569-573.

- Beltrando, G. (1990). Space-time variability of rainfall in April and October-November over East Africa during the period 1932-1983. *International Journal of Climatology*, 10, pp. 691-702.
- Beltrando, G., et Camberlin, P. (1993). Interannual variability of rainfall in the eastern Horn of Africa and indicators of atmospheric circulation. *International Journal of Climatology*, 13, pp. 533-546.
- Bertsekas, D.P., et Tsitsiklis, J.N. (1996). *Neuro-dynamic programming*, Athena Scientific, Belmont, MA, 491 pp.
- Bhansali, R.J., et D.Y.Downham. (1977). Some properties of the order of an autoregressive model selected by a generalization of Akaike's FPE criterion. *Biometrika*, 64, pp. 547-551.
- Bhatt, U.M. (1989). Circulation regimes of rainfall anomalies in the African-South Asian monsoon belt. *Journal of Climate*, 2, pp. 1133-1144.
- Billings, S.A., et Zhu, Q.M. (1994). Nonlinear model validation using correlation tests. *International Journal of Control*, 60(6), pp. 1107-1120.
- Birikundavyi, S., Trung, H.T., et Rousselle, J. (1999). Performance of neural networks in daily streamflow forecasting. *accepté pour publication au Journal of Hydrologic Engineering, ASCE*.
- Bishop, C.M. (1995). *Neural networks for pattern recognition*, Oxford University Press, Oxford, 482 pp.
- Bjerkens, J. (1969). Atmospheric teleconnections from the Equatorial Pacific. *Monthly Weather Review*, 97, pp. 163-172.
- Bliss, E.W. (1932). The Nile flood and world weather. *Memoirs of the Royal Meteorological Society*, 4(36), pp. 53-84.

- Boes, D.C., Davis, R.A., et Gupta, S.N. (1989). Parameter estimation in low order fractionally differenced ARMA processes. *Stochastic Hydrology and Hydraulics*, 3, pp. 97-110.
- Boes, D.C., et Salas, J.D. (1978). Nonstationarity of the mean and the Hurst phenomenon. *Water Resources Research*, 14, pp. 135-143.
- Bottomley, M., Folland, C.K., Hsiung, J., Newell, R.E., et Parker, D.E. (1990). Global Ocean Surface Temperature Atlas (GOSTA). Joint UK Meteorological Office and Massachusetts Institute of Technology Project. Project supported by US Dept. of Energy, US National Science Foundation and US Office of Naval Research. Publication funded by UK Depts. of the Environment and Energy., London, 20 + iv pp. et 313 figures.
- Box, G.E.P., et Cox, D.R. (1964). An analysis of transformations. *Journal of the Royal Statistical Society, Series B*, 26, pp. 211-243.
- Box, G.E.P., et Jenkins, G.M. (1976). *Time series analysis: forecasting and control*, Holden-Day, Oakland, California, 575 pp.
- Bras, R.L., et Rodriguez-Iturbe, I. (1985). *Random functions in hydrology*, Addison-Wesley, 559 pp.
- Brockwell, P.J., et Davis, R.A. (1991). *Time series: theory and methods*, Springer-Verlag, New York, 577 pp.
- Brooks, C.E.P. (1928). Periodicities in the Nile floods. *Memoirs of the Royal Meteorological Society*, 2(12), pp. 28.
- Brown, G.B., et Katz, R.W. (1991). Use of statistical methods in the search for teleconnections: past, present, and future. in *Teleconnections linking worldwide climate anomalies: scientific bases and societal impact*, Glantz, M. H., Katz, R. W., et Nicholls, N., eds., Cambridge University Press, pp. 371-400.

- Camberlin, P. (1993). Sécheresse et variabilité pluviométrique en Éthiopie et dans la Corne de l'Afrique : prolongements orientaux du Sahel ? *La Météorologie*, 8(3), pp. 26-35.
- Camberlin, P. (1994). *Les précipitations dans la Corne orientale de l'Afrique : climatologie, variabilité et connexions avec quelques indicateurs océano-atmosphériques*. Thèse de Doctorat, Université de Bourgogne, Dijon, 379 pp.
- Camberlin, P. (1997). Rainfall anomalies in the source region of the Nile and their connection with Indian summer monsoon. *Journal of Climate*, 10, pp. 1380-1392.
- Cheng, B., et Titterton, D.M. (1994). Neural networks: a review from a statistical perspective. *Statistical Science*, 9(1), pp. 2-54.
- Chitra, S.P. (1993). Use neural network for problem solving. *Chemical Engineering Progress*, 2, pp. 44-51.
- Chryssolouris, G., Lee, M., et Ramsey, A. (1996). Confidence interval prediction for neural network models. *IEEE Transactions on neural networks*, 7(1), pp. 229-232.
- Conway, D., et Hulme, M. (1993). Recent fluctuations in precipitation and runoff over the Nile subbasins and their impacts on Main Nile discharge. *Climatic Change*, 25, pp. 127-151.
- Conway, D., et Hulme, M. (1996). The impacts of climate variability and future climate change in the Nile basin on water resources in Egypt. *Water Resources Development*, 12, pp. 277-296.
- Conway, D., Krol, M., Alcamo, J., et Hulme, M. (1996). Future availability of water in Egypt: the interaction of global, regional, and basin scale driving forces in the Nile Basin. *Ambio*, 25, pp. 336-342.

- Crespo, J.L., et Mora, E. (1993). Drought estimation with neural networks. *Advances In Engineering Software*, 18(3), pp. 167-170.
- Crul, R.C.M., Silvestre, G.T., Postma, D.J., van Oijen, M.J.P., Acere, T.O., et Bongers, G. (1995). *A bibliography of Lake Victoria (East Africa)*, International Hydrological Programme - IV, United Nations Educational, Scientific and Cultural Organization, Paris, 164 pp.
- Currie, R.G. (1987). On bistable phasing of 18.6 year induced drought and flood on the Nile records since AD 650. *Journal of Climatology*, 1, pp. 373-390.
- Cury, K., et Bras, R.L. (1978). Theory and applications of the multivariate broken line, disaggregation, and monthly autoregressive streamflow generators to the Nile river. Report No. *TAP Report 78-5*, MIT, Massachusetts, 378 pp.
- Daniell, T.M. (1991). Neural networks. Applications in hydrology and water resources engineering. in *International Hydrology and Water Resources Symposium*, Barton, Perth, Australia, October 2-4 1991, pp. 797-802.
- Daniell, T.M., et Wundke, A.D. (1993). Neural networks assisting in water quality modeling. in *Proceedings of the 2nd Australasian Conference on Computing for the Water Industry Today and Tomorrow*, Melbourne, Australia, March 30-April 1 1993, pp. 51-57.
- Davies, T.D., Vincent, C.E., et Beresford, A.K.C. (1985). July-August rainfall in West-Central Kenya. *Journal of Climatology*, 5, pp. 17-33.
- Dawson, C.W., et Wilby, R. (1998). An artificial neural network approach to rainfall-runoff modelling. *Hydrological Sciences Journal*, 43(1), pp. 47-66.
- De Marsily, G. (1994). Quelques réflexions sur l'utilisation des modèles en hydrologie. *Revue des Sciences de l'Eau*, 7(3), pp. 219-234.

- De Veaux, R.D., Schumi, J., Schweinsberg, J., et Ungar, L.H. (1998). Prediction intervals for neural networks via nonlinear regression. *Technometrics*, 40, pp. 273-282.
- Delleur, J.W. (1986). Recursive parameter identification for flash flood forecasting. in *Multivariate Analysis of Hydrologic Processes, Proceedings of the Fourth International Hydrology Symposium*, Shen, H. W., Obeysekera, J. T. B., Yvejevich, V., et DeCoursey, D. G., eds., Colorado State University, Fort Collins, Engineering Research Center, Colorado State University, pp. 154-177.
- Demuth, H., et Beale, M. (1998). *Neural network toolbox, for use with Matlab: User's guide version 3*, The Math Works, Inc., Natick, MA, 13 chapitres.
- Dimopoulos, L., Lek, S., et Lauga, J. (1996). Modélisation de la relation pluie-débit par les réseaux connexionnistes et le filtre de Kalman. *Journal des Sciences Hydrologiques*, 41(2), pp. 179-193.
- Druyan, L.M. (1988). Sea-surface temperatures - Sahel drought teleconnections in GCM. in *Recent climatic change: a regional approach*, Gregory, S., ed., Belhaven Press, pp. 154-165.
- Efron, B. (1979). Bootstrap methods: another look at the jackknife. *Annals of Statistics*, 7, pp. 1-26.
- Efron, B., et Tibshirani, R.J. (1993). *An introduction to the bootstrap*, Chapman and Hall, New York, 436 pp.
- El-Fandy, M.G., Ashour, Z.H., et Tael, S.M.M. (1994). Time series models adaptable for forecasting Nile floods and Ethiopian rainfalls. *American Meteorological Society Bulletin*, 75, pp. 83-94.
- El-Sayed, A.H., et Errih, M. (1997). Multivariable MARIMA modeling of water resources time series: applications to River Nile ten-day discharges. in *Congress*

of the International Association of Hydraulic Research, IAHR, San Francisco, CA, USA, 10-15 August 1997, pp. 530-535.

Eltahir, E. (1996). El-Niño and the natural variability in the flow of the Nile River. *Water Resources Research*, 32, pp. 131-137.

Eltahir, E.A.B., et Wang, G. (1999). Nilometers, El-Niño, and climatic variability. *Geophysical Research letters*, 26(4), pp. 489-492.

Evans, T. (1994). History of Nile flows. in *The Nile: sharing a scarce resource. A historical and technical review of water management and of economic and legal issues*, Howell, P. P., et Allan, J. A., eds., Cambridge University Press, pp. 27-64.

Fahlman, S.E. (1989). Faster-learning variations on back-propagation: an empirical study. in *Proceedings of the 1988 Connectionist Models Summer School*, Touretzky, D., Hinton, G., et Sejnowski, T., eds., Morgan Kaufmann, pp. 38-51.

Farmer, G. (1988). Rainfall data bases and seasonal forecasting in Eastern Africa. in *Recent climatic change: a regional approach*, Gregory, S., ed., Belhaven Press, pp. 193-201.

Faure, H., et Gac, J.Y. (1981a). Will the Sahelian drought end in 1985? *Nature*, 291, pp. 475-478.

Faure, H., et Gac, J.Y. (1981b). Senegal river runoff, reply. *Nature*, 293, pp. 414.

Fay, D.M., Watt, W.E., et Watts, D.G. (1987). Stochastic real-time spring flood forecasting system for Carman, Manitoba. *Canadian Journal of Civil Engineering*, 14(1), pp. 87-96.

- Fleming, N. (1994). Comparison of water consumption forecasting methods including artificial neural networks. in *Proceedings of the Water Down Under*, Adelaide, Australia, November 21-25 1994, pp. 115-120.
- Flohn, H. (1987). Rainfall teleconnections in Northern and Northeastern Africa. *Theoretical and Applied Climatology*, 38, pp. 191-197.
- Folland, C.K., Owen, J., Ward, M.N., et Colman, A. (1991). Prediction of seasonal rainfall in the Sahel using empirical and dynamical methods. *Journal of Forecasting*, 10, pp. 21-56.
- Folland, C.K., Palmer, T.N., et Parker, D.E. (1986). Sahel rainfall and worldwide sea temperatures, 1901-85. *Nature*, 320, pp. 602-606.
- Folland, C.K., et Parker, D.E. (1990). Observed variations of sea surface temperature. in *Climate-ocean interaction*, Schlesinger, M. E., ed., Kluwer, Dordrecht, pp. 31-52.
- Folland, C.K., et Parker, D.E. (1995). Correction of instrumental biases in historical sea surface temperature data. *Quarterly Journal of the Royal Meteorological Society*, 121, pp. 319-367.
- Food and Agriculture Organization of the United Nations. (1993). Water policies and agriculture. Report No. *Agriculture Series No. 26*, FAO, Rome, Italy.
- Fortin, V., Ouarda, T.B.M.J., Rasmussen, P.F., et Bobée, B. (1997). Revue bibliographique des méthodes de prévision des débits. *Revue des Sciences de l'Eau*, 10(4), pp. 461-487.
- Franchini, M., Todini, E., Giuliano, G., et O'Connell, P.E. (1985). A multivariate, multiseasonal model for long term persistent hydrological series. in *Proceedings of the Fourth International Hydrology Symposium*, Shen, H. W. et al., eds., Fort Collins, Colorado, pp. 243-262.

- French, M.N., Krajewski, W.F., et Cuykendall, R.R. (1992). Rainfall forecasting in space and time using a neural network. *Journal of Hydrology*, 137, pp. 1-31.
- Geman, S., Bienenstock, E., et Doursat, R. (1992). Neural networks and the bias/variance dilemma. *Neural Computation*, 4, pp. 1-58.
- Georgakakos, A.P., et Yao, H. (1997). Nile basin management: G_T -NBM enhancements and river basin studies. Report No. *GIT/CEE-HYDRO-97-1*, School of Civil and Environmental Engineering, Georgia Institute of Technology, Atlanta, 174 pp.
- Georgakakos, A.P., Yao, H., et Yu, Y. (1995b). A decision support system for the High Aswan Dam. Report No. *GIT/CEE-HYDRO-95-2*, School of Civil and Environmental Engineering, Georgia Institute of Technology, Atlanta, 307 pp.
- Georgakakos, A.P., Yu, Y., et Yao, H. (1995a). Inflow forecasting models. Report No. *GIT/CEE-HYDRO-95-3*, School of Civil and Environmental Engineering, Georgia Institute of Technology, Atlanta, 208 pp.
- Gissila, T. (1997). The Nile and its variabilities as could be inferred from meteorological parameters. in *Proceedings of the fifth Nile 2002 conferences*, Addis-Ababa, 13 pp.
- Glantz, M.H. (1996). *Currents of change: El-Niño's impact on climate and society*, Cambridge University Press, 195 pp.
- Gleick, P. (1987). Regional hydrologic consequences of increases in atmospheric CO_2 and other trace gases. *Climatic Change*, 10, pp. 137-161.
- Goutte, C. (1997). Note on free lunches and cross-validation. *Neural Computation*, 9, pp. 1211-1215.
- Granger, C.W.J. (1969). Investigating causal relations by econometric models and cross-spectral methods. *Econometrica*, 37(3), pp. 424-438.

- Granger, C.W.J. (1980). Testing for causality: a personal viewpoint. *Journal of Economic Dynamics and Control*, 2, pp. 329-352.
- Granger, C.W.J., et Newbold, P. (1976). Forecasting transformed time series. *Journal of the Royal Statistical Society, Series B*, 38(2), pp. 189-203.
- Granger, C.W.J., et Newbold, P. (1986). *Forecasting economic time series*, Academic Press, Orlando, Florida, 338 pp.
- Haltiner, J.P., et Salas, J.D. (1988). Short-term forecasting of snowmelt runoff using ARMAX models. *Water Resources Research*, 24(5), pp. 1083-1089.
- Hameed, S. (1984). Fourier analysis of Nile flood levels. *Geophysical Research letters*, 1(9), pp. 843-845.
- Hameed, T., Marino, M.A., et Shumway, R.H. (1995). Evapotranspiration transfer-function-noise modeling. *Journal of Irrigation and Drainage Engineering, ASCE*, 121(2), pp. 159-169.
- Hansen, L.K., et Pedersen, M.W. (1994). Controlled growth of cascade correlation nets. in *Proceedings of the International Conference on Artificial Neural Networks, ICANN'94*, Marinaro, M., et Morasso, P. G., eds., Sorrento, Italy, pp. 796-800.
- Hara, Y., Atkins, R.G., Yueh, S.H., Shin, R.T., et Kong, J.A. (1994). Application of neural networks to radar image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 32(1), pp. 100-109.
- Hassan, F.A. (1981). Historical Nile floods and their implications for climatic change. *Science*, 212, pp. 1142-1145.
- Hassibi, B., et Stork, D.G. (1993). Second order derivatives for network pruning: optimal brain surgeon. in *Advances in Neural Information Processing Systems 5*,

- Hanson, S. J., ed., Denver, Colorado, 30 November - 3 December 1992, Morgan Kaufmann, pp. 164-171.
- Hastenrath, S. (1986). On climate prediction in the Tropics. *Bulletin of the American Meteorological Society*, 67, pp. 696-702.
- Hastenrath, S. (1991). *Climate dynamics of the tropics*, Kluwer, 488 pp.
- Haugh, L.D. (1976). Checking the independence of two covariance-stationary time series: a univariate residual cross-correlation approach. *Journal of the American Statistical Association*, 71(354), pp. 378-385.
- Haugh, L.D., et Box, G.E.P. (1977). Identification of dynamic regression (distributed lag) models connecting two time series. *Journal of the American Statistical Association*, 72, pp. 121-130.
- Haykin, S. (1999). *Neural networks: a comprehensive foundation*, Macmillan, NY, 842 pp.
- Heskes, T. (1997). Practical confidence and prediction intervals. in *Advances in Neural Information Processing Systems 9*, Mozer, M.C., Jordan, M.I., et Petsche, T., eds., Denver, CO, 1-6 December 1997, pp. 176-182.
- Hillel, D. (1994). *Rivers of Eden : the struggle for water and the quest for peace in the Middle East*, Oxford University Press, New York, 355 pp.
- Hillmer, S.C., et Tiao, G.C. (1979). Likelihood function of stationary multiple autoregressive moving average models. *Journal of the American Statistical Association*, 74, pp. 652-660.
- Hipel, K.W., et McLeod, A.I. (1978). Preservation of the rescaled adjusted range: 2. Simulation studies using Box-Jenkins models. *Water Resources Research*, 14, pp. 509-516.

- Hipel, K.W., et McLeod, A.I. (1994). *Time series modelling of water resources and enviromental systems*, Elsevier, Amsterdam, 1014 pp.
- Hipel, K.W., McLeod, A.I., et Noakes, D.J. (1982). Fitting dynamic models to hydrological time series. in *Time Series Methods in Hydrosiences*, El-Shaarawi, A. H., et Esterby, S. R., eds., Elsevier, Amsterdam, pp. 110-129.
- Hornik, K., Stinchcombe, M., et White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2, pp. 359-366.
- Howell, P.P., et Allan, J.A. (1994). The Nile: sharing a scarce resource. A historical and technical review of water management and of economic and legal issues. Cambridge University Press, 408 pp.
- Hsu, K.L., Gupta, H.V., et Sorooshian, S. (1995). Artificial neural network modeling of the rainfall-runoff process. *Water Resources Research*, 31(10), pp. 2517-2530.
- Hulme, M. (1988). Changes in wet season structure in central Sudan, 1900-1986. in *Recent climatic change: a regional approach*, Gregory, S., ed., Belhaven Press, pp. 154-165.
- Hulme, M. (1994). Global climate change and the Nile basin. in *The Nile: sharing a scarce resource. A historical and technical review of water management and of economic and legal issues*, Howell, P. P., et Allan, J. A., eds., Cambridge University Press, pp. 139-162.
- Hurst, H.E. (1957). *The Nile: a general account of the river and the utilization of its waters*, Constable, London, 331 pp.
- Hurst, H.E., Black, R.P., et Simaika, Y.M. (1965). *Long term storage: an experimental study*, Constable, London, 145 pp.

- Hutchinson, P. (1992). The Southern Oscillation and the prediction of the "Der" season rainfall in Somalia. *Journal of Climate*, 5, pp. 525-531.
- Hydromet (Institute of Hydrology). (1984). *A review of the hydrology of Lake Victoria*, ODA and Wallingford, London.
- Ichianagi, K., Goto, Y., Mizuno, K., Yokomizu, Y., et Matsumura, T. (1995). Artificial neural network to predict river flow rate into a dam for a hydro-power plant. In *Proceedings of the IEEE International Conference on Neural Networks*, Perth, Australia, November 27-December 1 1995, IEEE: N.J., pp. 2679-2682.
- Janicot, S., et Fontaine, B. (1993). L'évolution des idées sur la variabilité interannuelle récente des précipitations en Afrique de l'Ouest. *La Météorologie*, 8, pp. 23-53.
- Janowiak, J.E. (1988). An investigation of interannual rainfall variability in Africa. *Journal of Climate*, 1, pp. 240-255.
- Jonglei Investigation Team. (1946-1954). The Equatorial Nile project and its effects on the Anglo-Egyptian Sudan. Report No. , Sudan Government, Khartoum.
- Judge, G.G., Griffiths, W.E., Carter Hill, R., Lutkepohl, H., et Lee, T.-C. (1985). *The theory and practice of econometrics*, John Wiley and Sons, New York, 1019 pp.
- Kao, J.-J. (1996). Neural net for determining DEM-based model drainage pattern. *Journal of Irrigation and Drainage Engineering, ASCE*, 122(2), pp. 112-121.
- Karunanithi, N., Grenney, W.J., Whitley, D., et Bovee, K. (1994). Neural networks for river flow prediction. *Journal of Computing in Civil Engineering, ASCE*, 8(2), pp. 201-220.
- Kiladis, G.N., et van Loon, H. (1988). The Southern Oscillation. Part VII: meteorological anomalies over the Indian and Pacific sectors associated with the extremes of the oscillation. *Monthly Weather Review*, 116, pp. 120-136.

- Kite, G.W. (1981). Recent changes in level of Lake Victoria. *Hydrological Sciences Bulletin*, 26, pp. 233-243.
- Klemes, V. (1974). The Hurst phenomenon: a puzzle? *Water Resources Research*, 10, pp. 375-688.
- Knotters, M., et De Gooijer, J.G. (1999). TARSO modeling of water table depths. *Water Resources Research*, 35(3), pp. 695-705.
- Knotters, M., et van Walsum, P.E.V. (1997). Estimating fluctuation quantities from time series of water-table depths using models with a stochastic component. *Journal of Hydrology*, 197, pp. 25-46.
- Koren, V., et Barrett, C.B. (1994). Satellite based river forecast system for the Nile River. in *Proceedings of the 21st Annual Conference on Water Policy and Management: Solving the Problems*, Denver, CO, USA, May 23-26 1994, ASCE, New York, pp. 9-12.
- Lachtermacher, G., et Fuller, J.D. (1994). Backpropagation in hydrological time series forecasting. in *Proceeding of the Stochastic and Statistical Methods in Hydrology and Environmental Engineering*, Hipel, K. W., McLeod, A. I., Panu, U. S., et Singh, V. P., eds., Waterloo, ON, Canada, June 21-23 1993, Kluwer Academic Publishers, pp. 229-240.
- Lamb, P.J., et Pepler, R.A. (1991). West Africa. in *Teleconnections linking worldwide climate anomalies: scientific bases and societal impact*, Glantz, M. H., Katz, R. W., et Nicholls, N., eds., Cambridge University Press, pp. 121-189.
- Laukkanen, R. (1986). Transfer function noise models in the analysis of sewage treatment process interrelations. *Aqua Fennica*, 16(1), pp. 81-89.

- Le Cun, Y., Denker, J.S., et Solla, S.A. (1989). Optimal brain damage. in *Advances in Neural Information Systems 2*, Touretzsky, D., ed., Denver, CO, 27-30 November 1989, Morgan Kaufmann, pp. 598-605.
- Lin, B. (1995a). The impact of the ENSO on precipitation in Nile basin and its application to forecast operation (1). Report No. *Nile Technical Note 0196*, MTPRH et NOAA, 12 pp.
- Lin, B. (1995b). The impact of the ENSO on precipitation in Nile basin and its application to forecast operation (2). Report No. *Nile Technical Note 0197*, MTPRH et NOAA, 38 pp.
- Lin, B. (1995c). Steps of making a monthly LRQPF with an example of June 1995 issue. Report No. *Nile Technical Note 0198*, MTPRH et NOAA, 16 pp.
- Lippmann, R.P. (1987). An introduction to computing with neural networks. *IEEE Acoustics, Speech and Signal Processing Magazine*, 6, pp. 4-22.
- Liu, L.-M., et Hanssens, D.M. (1982). Identification of multiple-input transfer function models. *Communications in Statistics A*, 11, pp. 297-314.
- Liu, L.-M., Hudak, G.B., Box, G.E.P., Muller, M.E., et Tiao, G.C. (1994). *Forecasting and time series analysis using the SCA statistical system*, Scientific Computing Associates corporation, Oak Brook, Illinois, 9 chapitres.
- Ljung, G.M., et Box, G.E.P. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65, pp. 297-305.
- Lyons, H.G. (1906). *The physiography of the River Nile and its basin*, Government Press, Cairo.
- MACC. (1965). *GAUSHAUS -- Nonlinear least squares*, Madison Academic Computing Center, University of Wisconsin, Madison, WI.

- MacKay, D.J.C. (1992a). Bayesian interpolation. *Neural Computation*, 4, pp. 415-447.
- MacKay, D.J.C. (1992b). A practical bayesian framework for backpropagation networks. *Neural Computation*, 4, pp. 448-472.
- Maier, H.R., et Dandy, G.C. (1994). Forecasting salinity using neural networks and multivariate time series models. in *Proceedings of the Water Down Under*, Adelaide, Australia, November 21-25 1994, pp. 297-302.
- Mandelbrot, B.B., et Wallis, J.R. (1969). Computer experiments with Fractional Gaussian Noises. Part 1: Averages and variances. *Water Resources Research*, 5, pp. 228-241.
- Mangeas, M. (1997). Propriétés statistiques des modèles paramétriques non-linéaires de prévision de séries temporelles. Application aux réseaux de neurones à propagation directe. Report No. 97NJ00017, Electricité de France, Clamart, France, 205 pp.
- Markus, M., Salas, J.D., et Shin, H.S. (1995). Predicting streamflows based on neural networks. in *Proceedings of the 1st International Water Resources Engineering Conference*, San Antonio, TX, USA, August 14-18 1995, ASCE: NY, pp. 1641-1646.
- Marquardt, D. (1963). An algorithm for least-squares estimation of nonlinear parameters. *SIAM J. Appl. Math*, 11, pp. 431-441.
- Mason, J.C., Price, R.K., et Tem'me, A. (1996). A neural network model rainfall-runoff using basis functions. *Journal of Hydraulic Research*, 34(4), pp. 537-548.
- Master Plan of Water Resources Development and Use. (1981). Hydrological Simulation of Lake Nasser: I-Analysis and results. Report No. *Technical Report No. 14*, UNDP-EGY/73/024, Cairo, 213 pp.

- Masters, T. (1995). *Advanced algorithms for neural networks: a C++ sourcebook*, John Wiley and Sons, NY, 431 pp.
- McClave, J. (1975). Subset autoregression. *Technometrics*, 17, pp. 213-220.
- McCullogh, W.S., et Pitts, W.H. (1943). A logical calculus ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, pp. 115-133.
- McLeod, A.I. (1977). Improved Box-Jenkins estimators. *Biometrika*, 64(3), pp. 531-534.
- McLeod, A.I., Noakes, D.J., Hipel, K.W., et Thompstone, R.M. (1987). Combining hydrologic forecasts. *Journal of Water Resources Planning and Management, ASCE*, 113(1), pp. 29-41.
- Michie, D., Spiegelhalter, D.J., et Taylor, C.C. (1994). Machine learning, neural and statistical classification. Ellis Horwood, NY, 289 pp.
- Minns, A.W., et Hall, M.J. (1996). Artificial neural networks as rainfall-runoff models. *Hydrological Sciences Journal*, 41(3), pp. 399-417.
- Minsky, M.L., et Papert, S.A. (1969). *Perceptrons: an introduction to computational geometry*, MIT Press, Cambridge, MA, 258 pp.
- Moody, J.E. (1992). The effective number of parameters: an analysis of generalization and regularization in nonlinear learning systems. in *Advances in Neural Information Processing Systems 4*, Moody, J.E., Hanson, S.J., et Lippmann, R.P., eds., Denver, CO, 2-5 December 1991, pp. 847-854.
- Moore, R.J. (1982). Transfer functions, noise predictors, and the forecasting of flood events in real-time. in *Pre-Symposium Proceedings - International Symposium on Rainfall-Runoff Modeling*, Mississippi State, MS, pp. 229-250.

- Moron, V., Fontaine, B., et Roucou, P. (1995). Global equatorial variability of 850- and 200-hPa zonal rawsondes between 1963 and 1989. *Geophysical Research Letters*, 22, pp. 1701-1704.
- Navone, H.D., et Ceccatto, H.A. (1994). Predicting Indian monsoon rainfall: a neural network approach. *Climate Dynamics*, 10, pp. 305-312.
- Neal, R.M. (1996). *Bayesian learning for neural networks*, Springer-Verlag, New York, 183 pp.
- Nemec, J., et Schaake, J. (1982). Sensitivity of water resources systems to climate variation. *Hydrological Sciences Journal*, 27, pp. 327-343.
- Nicholson, S.E. (1985). Sub-Saharan rainfall 1981-84. *Journal of Climate and Applied Meteorology*, 24, pp. 1388-1391.
- Nicholson, S.E. (1997). An analysis of the ENSO signal in the Tropical Atlantic and Western Indian Oceans. *International Journal of Climatology*, 17, pp. 345-375.
- Nicholson, S.E., et Entekhabi, D. (1986). The quasi-periodic behavior of rainfall variability in Africa and its relationship to the Southern Oscillation. *Archiv für Meteorologie, Geophysik und Bioklimatologie*, 25, pp. 1351-1381.
- NOAA/OGP. (1992). International institute for climatic prediction: a proposal. Report No. MD: IRICP, NOAA, Silver Spring.
- Noakes, D.J., McLeod, A.I., et Hipel, K.W. (1985). Forecasting monthly riverflow time series. *International Journal of Forecasting*, 1, pp. 179-190.
- Nørgaard, M. (1997). Neural network based system identification toolbox, version 1.1, for use with Matlab. Report No. 97-E-851, Department of automation, Technical University of Denmark, Lyngby, Denmark, 96 pp.

- Novotny, V., et Zheng, S. (1990). Rainfall-runoff transfer function by ARMA modeling. *Journal of Hydraulic Engineering, ASCE*, 115(10), pp. 1386-1400.
- Ogallo, L.J. (1988). Relationships between seasonal rainfall in East Africa and the Southern Oscillation. *Journal of Climatology*, 8, pp. 31-43.
- Okoola, R.E. (1990). The stability of the South-East monsoons and the associated non-precipitating stratocumulus clouds over Eastern Africa. in *3rd WMO Symposium on Meteorological aspects of tropical droughts*, Niamey, WMO TMRP no. 36, pp. 65-70.
- Olason, T., et Watt, W.E. (1986). Multivariate transfer function-noise model of river flow for hydropower operation. *Nordic Hydrology*, 17(3), pp. 185-202.
- Palmer, T.N. (1986). Influence of the Atlantic, Pacific and Indian oceans on Sahel rainfall. *Nature*, 322, pp. 251-253.
- Pankratz, A. (1991). *Forecasting with dynamic regression models*, Wiley, New York, 386 pp.
- Parker, D.E., et Folland, C., K. (1991). Worldwide surface temperature trends since the mid-19th century. in *Greenhouse-gas-induced climatic change: a critical appraisal of simulations and observations*, Schlesinger, M. E., ed., Elsevier, Amsterdam, pp. 173-193.
- Parker, D.E., Folland, C.K., et Ward, M.N. (1988). Sea-surface temperatures anomaly patterns and prediction of seasonal rainfall in the Sahel region of Africa. in *Recent climatic change: a regional approach*, Gregory, S., ed., Belhaven Press, pp. 166-178.
- Parker, D.E., Jackson, M., et Horton, E.B. (1995). The 1961-1990 GISST2.2 sea surface temperature and sea-ice climatology. Report No. *Climate Research Technical*

- Note no. 63*, Hadley Centre for Climate Prediction and Research, United Kingdom Meteorological Office, Bracknell, Berkshire, 19 pp.
- Parthasarathy, B., Kupa Kumar, K., et Munot, A.A. (1991). Evidence of secular variations in Indian summer rainfall circulation relationships. *Journal of Climate*, 4, pp. 927-938.
- Piechota, T.C., et Dracup, J.A. (1999). Long-range streamflow forecasting using El-Niño / Southern Oscillation indicators. *Journal of Hydrologic Engineering, ASCE*, 4(2), pp. 144-151.
- Pierce, D.A. (1977). Relationships - and the lack thereof - between economic time series, with special reference to money and interest rates. *Journal of the American Statistical Association*, 72(357), pp. 11-21.
- Pipper, B.S., Plinston, D.T., et Sutcliffe, J.V. (1986). The water balance of Lake Victoria. *Hydrological Sciences Journal*, 31, pp. 25-37.
- Pitman, E.J.G. (1939). A note on normal correlation. *Biometrika*, 31, pp. 9-12.
- Potter, K.W. (1976). Evidence for nonstationarity as a physical explanation of the Hurst phenomenon. *Water Resources Research*, 12, pp. 1047-1052.
- Quinn, W.H. (1992). A study of Southern Oscillation-related climatic activity for A.D. 622-1900 incorporating Nile River flood data. in *El-Niño: Historical and paleoclimatic aspects of the Southern Oscillation*, Diaz, H. F., et Markgraf, V., eds., Cambridge University Press, pp. 119-149.
- Raman, H., et Sunilkumar, N. (1995). Multivariate modelling of water resources time series using artificial neural networks. *Hydrological Sciences Journal*, 40(2), pp. 145-163.

- Rao, A.R., Kayshap, R.L., et Mao, L.T. (1982). Optimal choice of type and order of river flow time series models. *Water Resources Research*, 18(4), pp. 1097-1109.
- Rao, C.R. (1973). *Linear statistical inference and its applications*, John Wiley, NY, 522 pp.
- Rasmussen, E.M., et Carpenter, T.H. (1982). Variations in tropical sea surface temperatures and surface wind fields associated with Southern Oscillation / El-Niño. *Monthly Weather Review*, 110, pp. 354-384.
- Reeves, C.R. (1993). *Modern heuristic techniques for combinatorial problems*. Wiley, NY, 320 pp.
- Reusing, G., et Skala, W. (1990). Drought risk analysis based on hydrologic records of the Nile River. in *Proceedings of the Int. Symposium on Hydraulics and Hydrology of Arid Lands*, French, R., ed., San Diego, CA, USA, July 30-August 2 1990, ASCE, pp. 495-500.
- Reynolds, R.W. (1988). A real-time global sea surface temperature analysis. *Journal of Climate*, 1, pp. 75-86.
- Ribeiro-Corréa, J., Évora, N., et Rousselle, J. (1995). Forecasting noisy hydrological data using artificial neural networks. in *Proceeding of the 15th Annual American Geophysical Union, Hydrology Days*, Morel-Seytoux, H. J., ed., Fort Collins, Co, pp. 251-258.
- Riedmiller, M., et Braun, H. (1993). A direct adaptive method for faster backpropagation learning: the RPROP algorithm. in *Proceedings of the IEEE International Conference on Neural Networks 1993*, San Francisco, CA, USA, March 28-April 1 1993, IEEE, pp. 586-591.
- Riehl, H., El-Bakry, M., et Meitin, J. (1979). Nile River discharge. *Monthly Weather Review*, 107, pp. 1546-1553.

- Ripley, B.D. (1994). Neural networks and related methods for classification. *Journal of the Royal Statistical Society, Series B*, 56, pp. 409-456.
- Ripley, B.D. (1996). *Pattern recognition and neural networks*, Cambridge University Press, Cambridge, 403 pp.
- Ropelewski, C.F., et Halpert, M.S. (1987). Global and regional scale precipitation patterns associated with the El-Niño / Southern Oscillation. *Monthly Weather Review*, 115, pp. 1606-1626.
- Ropelewski, C.F., Halpert, M.S., et Wang, X. (1992). Observed tropospheric biennial variability and its relationship to the Southern Oscillation. *Journal of Climate*, 5, pp. 594-614.
- Rosenblatt, F. (1962). *Principles of neurodynamics: perceptrons and the theory of brain mechanisms*, Spartan Books, Washington DC, 616 pp.
- Rowell, D.P., Folland, C.K., Maskell, K., et Ward, M.N. (1995). Variability of summer rainfall over tropical north Africa (1906-92) : observations and modelling. *Quarterly Journal of the Royal Meteorological Society*, 121, pp. 669-704.
- Rumelhart, D.E., Hinton, G.E., et Williams, R.J. (1986). Learning internal representations by error propagation. in *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Rumelhart, D. E., et McClelland, J. L., eds., The MIT Press., Cambridge, MA, pp. 318-362.
- Salas, J.D., Boes, D.C., Yevjevitch, V., et Pegram, G.G.S. (1979). Hurst phenomenon as a pre-asymptotic behavior. *Journal of Hydrology*, 44, pp. 1-15.
- Salas, J.D., Delleur, J.W., Yevjevich, V., et Lane, W. (1980). *Applied modeling of hydrologic time series*, Water Resources Publications, Littleton, Colorado, 484 pp.

- Salas, J.D., Saada, N.M., et Chung, C.-H. (1995). Stochastic modeling and simulation of the Nile river system monthly flows. Report No. *Technical report No.5*, Colorado State University, Fort Collins, Colorado, 251 pp.
- Sarle, W.S. (1995). Stopped training and other remedies for overfitting. in *Proceedings of the 27th Symposium on the Interface of Computing Science and Statistics*, , pp. 352-360.
- Sarle, W.S., ed. (1999). Neural network FAQ, part 1 of 7: Introduction, periodic posting to the Usenet newsgroup comp.ai.neural-nets, URL:
<ftp://ftp.sas.com/pub/neural/FAQ.html>. , pp. .
- Schaake, J.C. (1990). From climate to flow. in *Climate change and U. S. water resources*, Waggoner, P. E., ed., John Wiley and Sons, pp. 177-206.
- Schaake, J.C. (1993). PP6: Operational precipitation gage-only analysis procedures (NFS Version 2.0). Report No. *Nile Technical Note 0011.4*, MTPRH et NOAA, 18 pp.
- Schaake, J.C., et Newby (Green), J. (1993). Satellite estimation using the Nile climatological method. Report No. *Nile Technical Note 0006*, MTPRH et NOAA, 14 pp.
- Schwarz, G. (1978). Estimating the dimension of a model. *The Annals of Statistics*, 6, pp. 461-464.
- Seleshi, Y. (1997). Causes and variabilities of summer rainfall and runoff over the Highlands of the Nile River basin. in *Proceedings of the fifth Nile 2002 conferences*, Addis-Ababa, 13 pp.
- Seleshi, Y., et Demaree, G.R. (1995). Rainfall variability in the Ethiopian and Eritrean highlands and its links with the Southern Oscillation Index. *Journal of Biogeography*, 22, pp. 945-952.

- Seleshi, Y., Demaree, G.R., et Delleur, J.W. (1994). Sunspot numbers as a possible indicator of annual rainfall at Addis Ababa, Ethiopia. *International Journal of Climatology*, 14, pp. 911-923.
- Shahin, M. (1985). *Hydrology of the Nile basin*, Elsevier, Amsterdam, 575 pp.
- Shahin, M. (1990). Annual flow variations in the Nile River system. in *Proceedings of the Int. Symposium on Hydraulics and Hydrology of Arid Lands*, French, R., ed., San Diego, CA, USA, July 30-August 2 1990, ASCE, pp. 7-13.
- Shahin, M., Van Oorschot, H.J.L., et DeLange, S.J. (1993). *Statistical analysis in water resources engineering*, Balkema, Rotterdam, 394 pp.
- Shibata, R. (1976). Selection of the order of an autoregressive model by Akaike's Information Criterion. *Biometrika*, 63, pp. 117-126.
- Smith, J., et Eli, R.N. (1992). Streamflow forecasting using trainable neural networks. in *National Conference on Water Resources Planning and Management*, Baltimore, MD, USA, August 2-6 1992, ASCE: NY, pp. 56-61.
- Smith, J., et Eli, R.N. (1995). Neural-network models of rainfall-runoff processes. *Journal of Water Resources Planning and Management, ASCE*, 121(6), pp. 499-508.
- Snorrason, A., et Einarsson, K. (1986). Transformation of input to a stochastic model using a distributed deterministic model. *Nordic Hydrology*, 17, pp. 371-382.
- Snorrason, A., Newbold, P., et Maxwell, W.H.C. (1984). Multiple input transfer function-noise modeling of riverflow. Water Resources Publication, Fort Collins, Colorado, pp. 111-126.
- Sutcliffe, J., et Lazenby, J. (1994). Hydrological data requirements for planning Nile management. in *The Nile: sharing a scarce resource. A historical and technical*

review of water management and of economic and legal issues, Howell, P. P., et Allan, J. A., eds., Cambridge University Press, pp. 163-192.

Szalay, M. (1973). Forecasting of flood characteristics of the Nile. in *Proceedings of the International Symposium on River Mechanics*, Bangkok, Thailand, January 9-12 1973, IAHR, B38 pp. 1-11.

Tabios, G., et Salas, J.D. (1982). Forecasting snowmelt runoff. in *Proceeding of the International Symposium on Hydrometeorology*, , AWRA, pp. 213-217.

Thapliyal, V., et Kulshrestha, S.M. (1992). Recent models for long-range forecasting of southwest monsoon rainfall in India. *Mausam*, 43, pp. 239-248.

Thirumalaiah, K., et Deo, M.C. (1998). River stage forecasting using artificial neural networks. *Journal of Hydrologic Engineering, ASCE*, 3(1), pp. 26-32.

Thompstone, R.M., Hipel, K.W., et McLeod, A.I. (1983). Transfer function-noise modelling for powerhouse inflow forecasting. *INFOR Journal (Canadian Journal of Operational Research and Information Processing)*, 21(4), pp. 258-269.

Thompstone, R.M., Hipel, K.W., et McLeod, A.I. (1985). Forecasting quarter-monthly riverflow. *Water Resources Bulletin*, 21(5), pp. 731-741.

Tibshirani, R. (1996). A comparison of some error estimates for neural network models. *Neural Computation*, 8, pp. 152-163.

Trenberth, K.E. (1991). General characteristics of El-Niño - Southern Oscillation. in *Teleconnections linking worldwide climate anomalies: scientific bases and societal impact*, Glantz, M. H., Katz, R. W., et Nicholls, N., eds., Cambridge University Press, pp. 13-42.

- Trzaska, S., Camberlin, P., et Fontaine, B. (1996a). Impact des modes globaux de variabilité des températures océaniques sur les précipitations africaines de la mousson d'été boréal. in *Seconde conférence internationale de la société météorologique africaine*, Rabat, Maroc, 25-28 novembre, 11 pp.
- Trzaska, S., Moron, V., et Fontaine, B. (1996b). Global atmospheric response to specific linear combinations of the main SST modes. Part I: numerical experiments and preliminary results. *Annales Geophysicae*, 14, pp. 1066-1077.
- Vapnik, V. (1992). Principles of risk minimization for learning theory. in *Advances in Neural Processing Systems 4*, Denver, CO, 2-5 December 1991, pp. 831-838.
- Walker, G.T. (1923). Correlation in seasonal variations of weather, VII: A preliminary study of world weather. *Memoirs of the Indian Meteorological Department*, 24, pp. 75-131.
- Walker, G.T., et Bliss, E.W. (1932). World weather V. *Memoirs of the Royal Meteorological Society*, 4, pp. 53-84.
- Wang, G., et Eltahir, E.A.B. (1999). Use of ENSO information for medium- and long-range forecasting of the Nile floods. *Journal of Climate*, 12(6), pp. 1726-1737.
- Weigend, A.S., Rumelhart, D.E., et Huberman, B.A. (1990). Predicting the future: a connectionist approach. *International Journal of Neural Systems*, 1(3), pp. 193-209.
- Weigend, A.S., Rumelhart, D.E., et Huberman, B.A. (1991). Generalization by weight-elimination with application to forecasting. in *Advances in Neural Information Processing Systems 3*, Lippmann, R. P., Moody, J. E., et Touretzky, D. S., eds., Denver, CO, 26-29 November 1990, Morgan Kaufmann, pp. 875-882.

- Wen, C.-G., et Lee, C.-S. (1998). A neural network approach to multiobjective optimization for water quality management in a river basin. *Water Resources Research*, 34(3), pp. 427-436.
- Werbos, P.J. (1974). *Beyond regression: new tools for prediction and analysis in the behavioral sciences*. Thèse de doctorat, Harvard University, Cambridge, MA., pp.
- Whetton, P., et Rutherford, I. (1994). Historical ENSO teleconnections in the Eastern Hemisphere. *Climatic Change*, 28, pp. 221-253.
- White, H. (1992). *Artificial neural networks: approximation and learning theory*, Blackwell.
- Whittington, D., et Guariso, G. (1983). *Water management models in practice: a case study of the Aswan High Dam*, Elsevier, 246 pp.
- Wilcoxon, F. (1945). Individual comparison by ranking methods. *Biometrics*, 1, pp. 80-83.
- Williams, M.A.J., et Faure, H. (1980). *The Sahara and the Nile*. Balkema, Rotterdam, 607 pp.
- Wood, C.A., et Lovett, R. (1974). Rainfall, drought and the solar cycle. *Nature*, 251, pp. 594-596.
- Woodruff, S.D., Slutz, R.J., Jenne, R.L., et Steurer, P.M. (1987). A Comprehensive Ocean Atmosphere Data Set. *Bulletin of the American Meteorological Society*, 68, pp. 1239-1250.
- Wright, P.B. (1989). Homogenized long-period Southern Oscillation indices. *International Journal of Climatology*, 9, pp. 33-54.

- Yevjevich, V. (1967). Mean range and linearly dependent normal variables with applications to storage problems. *Water Resources Research*, 3, pp. 663-671.
- Yin, X., et Nicholson, S.E. (1998). Water balance of Lake Victoria. *Hydrological Sciences Journal*, 43(5), pp. 789-811.
- Zhang, S.P., Watanabe, H., et Yamada, R. (1994). Prediction of daily water demands by neural networks. in *Proceeding of the Stochastic and Statistical Methods in Hydrology and Environmental Engineering*, Hipel, K. W., McLeod, A. I., Panu, U. S., et Singh, V. P., eds., Waterloo, ON, Canada, June 21-23 1993, Kluwer Academic Publishers, pp. 217-226.
- Zhu, M.L., Fujita, M., et Hashimoto, N. (1994). Application of neural networks to runoff prediction. in *Proceeding of the Stochastic and Statistical Methods in Hydrology and Environmental Engineering*, Hipel, K. W., McLeod, A. I., Panu, U. S., et Singh, V. P., eds., Waterloo, ON, Canada, June 21-23 1993, Kluwer Academic Publishers, pp. 205-216.