

Application des réseaux de neurones formels pour la prévision des débits mensuels du Bandama blanc à la station de Tortiya (Nord de la Côte d'Ivoire)

Yao Blaise KOFFI^{1*}, Kouassi Ernest AHOUSI¹, Amani Michel KOUASSI², Ouattara KOUASSI¹, Loukou Christophe KPANGUI¹ et Jean BIEMI¹

¹ *Université de Cocody, Unité de Formation et de Recherche (UFR) des Sciences de la Terre et des Ressources Minières (STRM), 22 BP 582 Abidjan 22, Côte d'Ivoire*

² *Institut National Polytechnique Félix Houphouët-Boigny (INP-HB), Département des Sciences de la Terre et des Ressources Minières (STeRMi), Laboratoire du Génie Civil, des Géosciences et des Sciences Géographiques, BP 1093 Yamoussoukro, Côte d'Ivoire*

*Correspondance, courriel : yaomonie@yahoo.fr

Résumé

Plusieurs travaux témoignent de la capacité des réseaux de neurones à modéliser les débits des rivières. Malheureusement on ignore actuellement si ces modèles neuronaux sont performants pour la prévision du binôme pluie-débit en régime tropical humide en général et particulièrement sur le Bandama Blanc dans le Nord de la Côte d'Ivoire. Ce travail de recherche permettra de vérifier l'efficacité des réseaux de neurones formels pour la prévision des débits mensuels du Bandama Blanc à partir de la relation pluie-débit qui est non-linéaire. Trois modèles de réseaux de neurones ont donc été optimisés afin d'atteindre cet objectif. Une base de données composée du débit, de la pluie, de la température et de l'Evapotranspiration Potentiel (ETP) au pas de temps mensuel à été utilisée comme entrée de ces modèles.

Ces données ont été normalisées entre 0 et 1 et subdivisées en deux blocs : un premier bloc composé des 2/3 des données (1971-1988) pour l'apprentissage et un second bloc composé du 1/3 des données (1989-1997) pour la validation. Ces modèles ont été optimisés avec l'apprentissage supervisé. Le critère de Nash-Sutcliffe et le coefficient de corrélation (R) ont été utilisés pour tester la performance de ces modèles. Les résultats obtenus montrent que tous les modèles expriment plus de 70% de la variation des débits du Bandama Blanc à Tortiya. Pour tous ces modèles, les valeurs du critère de Nash-Sutcliffe calculées sont nettement supérieures à 70% et les coefficients de corrélation de Pearson sont très élevés et supérieurs à 0,80. Mais, malgré ces bonnes performances, les débits extrêmes sont généralement mal modélisés.

Mots-clés : *modélisation, apprentissage, perceptron multicouches, rivière.*

Abstract

Several studies demonstrate the ability of neural networks to model the river flows. Unfortunately it is currently unknown if these neural models are effective for predicting rainfall-runoff in humid tropical regime in general and particularly on the river "Bandama Blanc" where the water system is disturbed by the presence of many agro -pastoral dams. Three models of neural networks have been optimized to give an answer to this problem. A database consisting of flow, rainfall, temperature and potential evapotranspiration (PET) on a monthly time has been used as input to these models.

These data were normalized between 0 and 1 and divided into two blocks: a first block consists of 2/3 of the data (1971-1988) for learning and a second block consisting of 1/3 of the data (1989-1997) for the validation of these models. These models have been optimized with supervised learning in the environment RNF PRO. The Nash-Sutcliffe and the correlation coefficient (R) were used to test the performance of these models. The results show that all models express more than 70% of the variation in rates of the river "Bandama Blanc" at Tortiya station. We also note that for all these models, criteria Nash-Sutcliffe calculated are more higher than 70% and the Pearson correlation coefficients are very higher than 0.80. But despite this good performance, we notice that the extreme flows are generally poorly modeled.

Keywords : *modeling, learning, multilayer perceptron, river.*

1. Introduction

Les précipitations constituent généralement les plus grands apports du bilan hydrologique d'un bassin versant [1]. Elles sont généralement constituées par les bruines, les verglas, les givres, les neiges, les grêles, les grésils et les pluies. Mais, en Afrique en général et particulièrement en Côte d'Ivoire, c'est la pluie uniquement qui alimente les nappes et les différents cours d'eau [2]. La transformation de la pluie (P) en débit (Q) des rivières et des fleuves est un phénomène de grande importance qui, depuis plusieurs années, fait l'objet de nombreuses études. La communauté scientifique dans son ensemble, afin de faire face aux problèmes d'eau (inondation, sécheresse, etc.), utilise différents modèles (modèles distribués, modèles globaux, etc.) pour la compréhension de la relation pluie-débit qui est dans la plupart des cas non-linéaire.

Dans le cas du Bandama Blanc, objet de cette étude, cette non-linéarité est accentuée par la présence de plusieurs barrages à vocation agro-pastorale. Beaucoup de méthodes statistiques conventionnelles de modélisation sont basées sur des modèles linéaires (Modèle ARIMA, modèle AR, etc.), alors que le succès de ceux-ci est limité par leur linéarité. Pour pallier cette non-linéarité et construire des modèles qui se rapprochent plus de la réalité, plusieurs modèles sont essayés dont les réseaux de neurones. Les travaux de plusieurs auteurs dans ce domaine montrent que ces modèles, inspirés du fonctionnement des neurones biologiques, sont très performants pour la simulation et la prévision des débits sur les bassins versants. Dans ce domaine, plusieurs études menées en Amérique [3], en Europe [4,5] et en Algérie [6,7] confirment ces meilleurs résultats de simulation et de prévision avec les réseaux de neurones.

Malheureusement on ignore actuellement si ces modèles neuronaux sont performants pour la prévision du binôme pluie-débit en régime tropical humide en général et particulièrement sur le Bandama Blanc où le régime des eaux, voire la relation pluie-débit, est perturbé par la présence de plusieurs barrages agro-pastoraux. Comment ces modèles inspirés de la biologie se comportent-ils alors en prévision sur le Bandama Blanc à la station de Tortiya ? Ce travail de recherche permettra de vérifier l'efficacité des réseaux de neurones formels pour la prévision des débits mensuels du Bandama Blanc dans un contexte de non-linéarité de la relation pluie-débit. Ainsi, après avoir présenté la zone d'étude et les données utilisées, les différentes variantes de modèles neuronaux, les méthodes de validation seront détaillées. Cet article se focalisera sur les résultats obtenus et les discussions que soulèvent ces résultats.

2. Présentation de la zone d'étude et des données utilisées

2-1. Localisation et présentation de la zone d'étude

Le sous bassin versant du Bandama objet de cette étude est situé en amont du barrage hydroélectrique de Kossou. On y rencontre un plus grand nombre de barrages hydro agricoles, soit 85% de tous les barrages de ce genre dans tout le Nord de la Côte d'Ivoire. Les limites géographiques de cette zone sont (**Figure 1**): le bassin versant de la Marahoué à l'Ouest ; le bassin versant du N'zi à l'Est ; le bassin versant de la Volta au Nord et ; au Sud, la retenue d'eau du lac de Kossou.

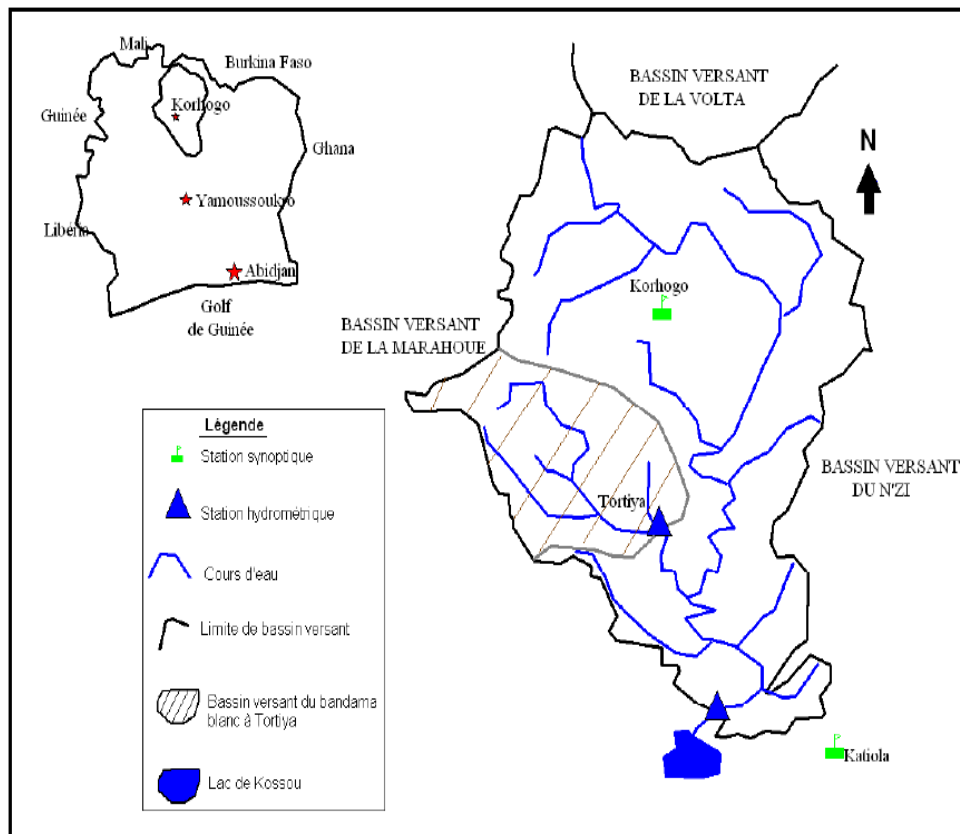


Figure 1: Localisation du bassin versant d'étude

La zone d'étude appartient au bassin versant du Bandama à Bada. Son choix se justifie d'une part par le fait qu'elle renferme plus de 85% des barrages agropastoraux situés dans ce bassin versant, ce qui représente un enjeu important en termes de gestion de la ressource en eau. D'autre part, elle est située juste au-dessus du barrage hydroélectrique de Kossou, ce qui évite les problèmes de propagation lors de l'utilisation des modèles pluie-débit. La zone est également géomorphologiquement homogène, avec des altitudes variant de 200 à 300 m. Enfin, les sols y sont généralement ferrallitiques et la végétation de type savanicole. Sur le plan des ressources en eaux souterraines, le bassin versant d'étude présente des aquifères fissurés surmontés des aquifères d'altérites. Concernant les eaux de surface, on note un régime relativement simple, avec un minimum en février et un maximum en septembre [2].

2-2. Présentation des données de l'étude

Les présents travaux s'appuient sur une importante base de données (pluie, température, ETP et débit) couvrant l'ensemble de la zone d'étude. Elles sont le résultat de plusieurs campagnes de mesure effectuées par la Société d'Exploitation et de Développement Aéroportuaire, Aéronautique et Météorologique (SODEXAM) et le Système d'Information Intégré de Base de Données (IDIS). En ce qui concerne les données de débit, elles ont été obtenues auprès de la Sous-Direction de l'Hydrologie de la Direction de l'Hydraulique Humaine. Les données de pluies et de températures fournies par la SODEXAM concernent celles des stations synoptiques de Korhogo et de Katiola. Pour la station de Korhogo l'étendue de la série des précipitations mensuelles obtenues est de 29 ans (de 1971 à 2000) avec des lacunes. En effet, 12,9 3% des données de pluie collectées sont aberrantes. En ce qui concerne les températures à Korhogo, 30 ans de mesures (de 1971 à 2001) sont disponibles. Pour la station de Katiola, les pluies journalières de 1949 à 2000 ont pu être collectées, soit 51 années d'observation.

Ces pluies journalières ont été transformées en pluies mensuelles. Il faut signaler que les irrégularités observées dans la série de pluie de la station de Korhogo n'apparaissent pas au niveau de la station de Katiola. Le Système d'Information Intégré de Base de Données (IDIS) a fourni des valeurs de précipitation et de température mensuelles sur la période 1900 à 2002. Des analyses statistiques des données de la SODEXAM et du système IDIS montrent qu'au niveau de la température, l'écart moyen entre les valeurs et la moyenne des températures est respectivement de 1,51 pour les températures IDIS et de 1,66 pour celles de la SODEXAM [2]. En ce qui concerne les pluies, les statistiques sont différentes pour les deux sources de données. Dans un contexte de modélisation pluie-débit, il est généralement intéressant d'utiliser des variables climatiques issues d'une même base de données. Mais, la base de données fournie par la SODEXAM présente beaucoup de lacunes et plusieurs valeurs sont aberrantes.

Pour résoudre ce problème de données, il a donc fallu avoir recours aux données IDIS, qui sont plus complètes. En effet dans cette étude, les pluies IDIS sont utilisées pour combler les lacunes dans les séries de pluies de la SODEXAM. En ce qui concerne les températures IDIS, elles sont utilisées comme entrée des différents modèles développés. Dans cette étude, pour éviter que pendant l'apprentissage des réseaux de neurones les plus petites valeurs n'aient pas d'influence, les données ont donc été normées entre 0 et 1. Une fois les variables normées, elles ont été regroupées selon la méthode du " *simple split-sample test*" [8], notamment parce qu'elle est simple et fréquemment utilisée en hydrologie. Ainsi les 2/3 des données (1971-1988) seront choisies pour la phase d'apprentissage et le 1/3 (1989-1997) pour la phase de validation. Les valeurs d'EvapoTranspiration Potentielle (ETP) ont été calculées avec la méthode de Thornthwaite.

3. Méthodologie

3-1. Présentation des réseaux de neurones

Le réseau de neurone est défini comme un assemblage d'éléments de structure identique appelés cellules (ou neurones) interconnectées à l'instar des cellules du système nerveux des vertébrés [9]. Des neurones biologiques, les auteurs comme [10-15] se sont inspirés pour mettre au point les neurones formels ou artificiels. Des similitudes ont donc été établies entre les éléments des neurones biologiques et les composantes des Neurones Formels ou Artificiels (*Figure 2*).




Figure 2 : Analogie entre neurone biologique et neurone formel [16]

Plusieurs architectures de réseaux de neurones existent [16]. Mais, le Perceptron Multicouches, qui est une extension du Perceptron Monocouche, avec une ou plusieurs couches cachées entre l'entrée et la sortie est utilisé dans cette étude. Au niveau de cette architecture, chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante (excepté pour les couches d'entrée et de sortie) et il n'y a pas de connexions entre les cellules d'une même couche. Ce type de réseaux a été récemment classé comme outil de prévision et de simulation des débits [17]. La **Figure 3** représente un Perceptron Multicouches avec une seule couche de neurones cachés. Les variables d'entrée sont la pluie et la température et la variable cible est le débit.

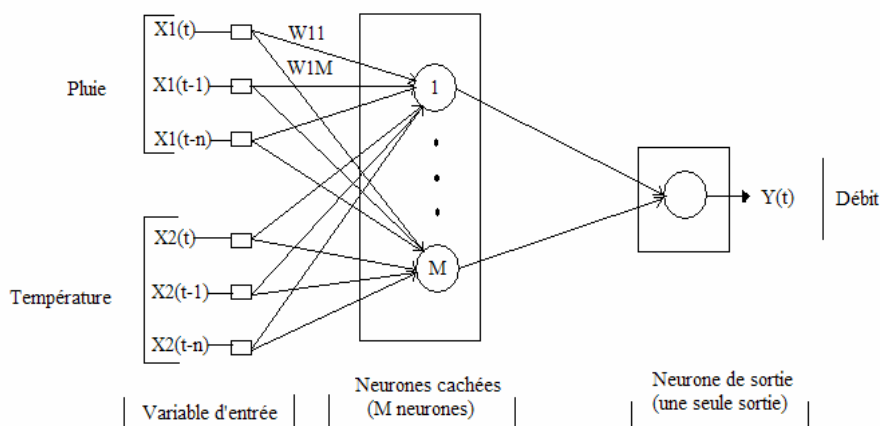


Figure 3 : Perceptron Multicouche simplifié avec une seule couche de neurones cachés [2]

L'avantage de l'utilisation des réseaux de neurones dans la modélisation en hydrologie est perçu par leur capacité à tenir compte de la non linéarité de la relation pluie-débit [18]. Il s'agit en fait d'une propriété très intéressante pour ne considérer que les paramètres météorologiques d'autant plus que les autres paramètres qui peuvent influencer le débit (occupation du sol, paramètres géologique, géomorphologique, hydrogéologique, etc.) ne sont pas considéré dans cette étude. Plusieurs environnements sont disponibles pour le développement des Réseaux de neurones notamment Matlab, Statistica, Scilab, *RNF PRO*, etc., mais dans cette étude, c'est le compilateur "*RNF PRO*" a été utilisé. Les différents poids (paramètres) des modèles neuronaux ont été ajustés dans cet environnement informatique en appliquant l'apprentissage supervisé avec l'algorithme Levenberg Marquardt (LM) [19].

Le choix de la structure des modèles neuronaux est un compromis entre le sous-apprentissage et le sur-apprentissage [20]. Plusieurs règles heuristiques existent pour suggérer a priori un nombre de neurones cachés en fonction du nombre d'observations en apprentissage et du nombre d'entrée du modèle. Cependant, ces règles empiriques dépendent de la nature des données utilisées et du bruit qui entache ces données. Elles ne sont donc pas à généraliser [21]. Il faut pour ce faire procéder avec une démarche du type "essais-erreurs" utilisée dans cette étude pour déterminer les différents retards et le nombre de neurones sur la couche cachée [2]. Cette démarche a permis de mettre en place les modèles neuronaux dont les architectures sont résumées dans les paragraphes suivants.

3-1-1. Modèle PMCD1p

Les entrées, du modèle PMCD1p représenté à la **Figure 4**, sont les précipitations et le débit mesuré. Les retards de ces entrées sont égaux à 12 et 1 respectivement pour les pluies et les débits mesurés. On dénombre 3 neurones sur la couche cachée de ce réseau. Le réseau prend en compte les pluies des 12 derniers mois et des débits du mois qui précède les trois mois avant le mois de la prévision.

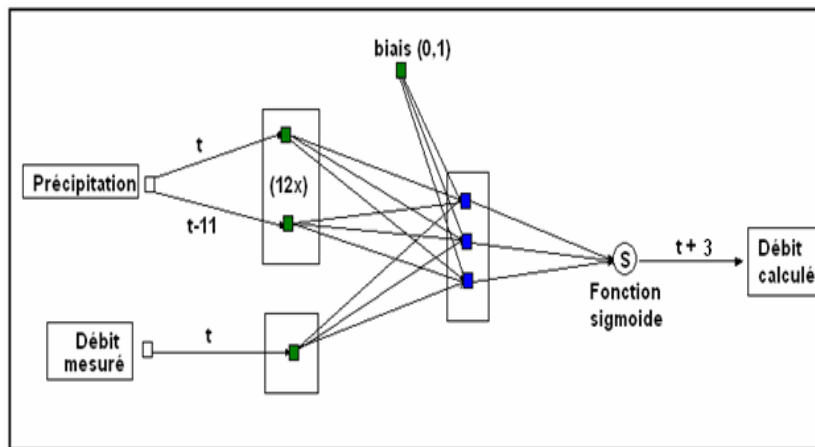


Figure 4 : Architecture simplifiée du modèle PMCD1p

3-1-2. Modèle PMCD3p

La **Figure 5** représente le modèle de prévision PMCD3p avec trois variables en entrée.

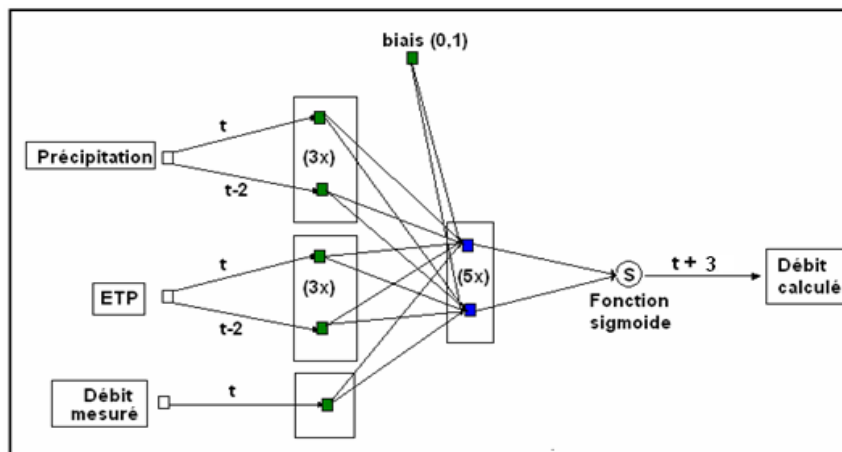


Figure 5 : Architecture simplifiée du modèle PMCD3p

Ces variables explicatives sont la pluie, l'évapotranspiration potentielle et les débits mesurés. Pour ce modèle, le nombre de retard est estimé à 3 mois pour la pluie et l'évapotranspiration potentielle et de 1 mois pour les débits mesurés. En ce qui concerne le nombre de neurones sur la seule couche cachée, il est égal à 5. Le réseau prend en compte les précipitations et les évapotranspirations des 3 derniers mois et des débits du mois qui précède les trois mois avant le mois de la prévision. Dans ce modèle également, on observe une diminution du retard des variables explicatives avec l'ajout de l'évapotranspiration potentielle qui passe de 11 mois pour le modèle PMCD1p à 3 mois pour le modèle PMCD3p.

3-1-3. Modèle PMCD4p

Tout comme les modèles PMCD2p et PMCD3p, le modèle PMCD4p, représenté à la **figure 6**, possède trois variables en entrée : la pluie, la température et le débit.

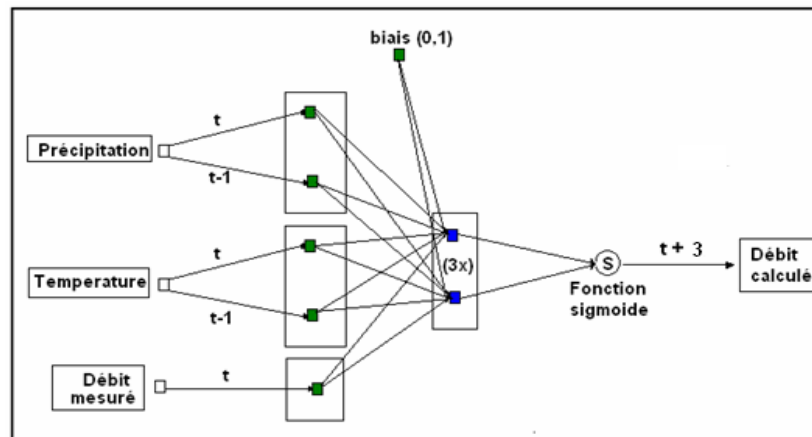


Figure 6: Architecture simplifiée du modèle PMCD4p

En conclusion, on note qu'à part le modèle PMCD1p qui comporte un nombre élevé de retard (12 mois), le reste des modèles a un nombre de retard compris généralement entre 2 et 4 mois. En ce qui concerne le nombre de neurones cachés, il varie de 2 à 5.

3-2. Critères d'optimisation des modèles développés

De nombreux critères sont utilisés en hydrologie pour évaluer la performance des modèles, notamment : le Critère de Nash-Sutcliffe et le coefficient de corrélation R [2]. Le critère de Nash-Sutcliffe est donné par l'équation 1.

$$Nash = (100) \times \left(1 - \frac{\sum_i (T_i - P_i)^2}{\sum_i (T_i - \bar{P})^2} \right) \tag{1}$$

avec :

T_i et P_i respectivement les débits mesurés (observés) et calculés pour les $i=1, \dots, N$, \bar{P} est la moyenne des débits calculés. Le critère de Nash-Sutcliffe [22] varie de $-\infty$ à 1 et l'échelle suivante est généralement utilisée [23] :

- $\geq 90\%$ le modèle est excellent ;
- 80% à 90% , le modèle est très bon ;
- 60% à 80% , le modèle est bon et
- $\leq 60\%$, le modèle est mauvais.

En ce qui concerne le coefficient de corrélation de Pearson, il est habituellement utilisé pour évaluer la performance des modèles hydrogéologiques et hydrologiques [24]. Il est obtenu en calculant la régression linéaire entre les valeurs (débits) calculées et les valeurs (débits) observées ou mesurées. Sa formulation est donnée par l'équation 2.

$$R = \frac{\sum_{i=1}^N t_i P_i}{\sqrt{(\sum_{i=1}^N t_i^2)} \sqrt{(\sum_{i=1}^N P_i^2)}} \quad (2)$$

avec :

T_i et P_i respectivement les débits observés et calculés pour les $i=1, \dots, N$, \bar{T} et \bar{P} sont les moyennes respectives des débits observés et calculés. N , le nombre d'entrées ; $t_i = T_i - \bar{T}$, $p_i = P_i - \bar{P}$, La corrélation entre les débits observés et les débits calculés est [24] : parfaite si $R = 1$; très forte si $R > 0,8$; forte si R se situe entre 0,5 et 0,8 ; d'intensité moyenne si R se situe entre 0,2 et 0,5 ; faible si R se situe entre 0 et 0,2 ; nulle si $R = 0$.

L'une des techniques les plus utilisées, pour évaluer la robustesse d'un modèle dans les situations les plus proches possibles de celles dans lesquelles il est censé fonctionner, est la technique du double échantillon [25]. Cette technique permet de tester l'adaptabilité du modèle quelle que soit sa complexité. La robustesse implique que les résultats pouvant être obtenus par simulation avec le modèle ne divergent pas lorsque la valeur des variables d'entrée est légèrement modifiée du fait des erreurs et des incertitudes qui leur sont associées, mais qu'ils sont sensibles aux variations des facteurs dont on cherche à estimer les effets. Le critère de robustesse du modèle a été évalué par la valeur absolue de la différence de la valeur du critère de Nash-Sutcliffe en calage et en validation. Le modèle est dit robuste si le critère de robustesse est inférieur ou égal à 10%.

4. Résultats

4-1. Performance des modèles développés

L'analyse des résultats obtenus (*Tableau 1*) montre que, dans l'ensemble, tous les modèles expriment plus de 70% de la variation des débits du Bandama Blanc à Tortiya. Pour tous les modèles, les valeurs du critère de Nash-Sutcliffe calculés sont nettement supérieures à 70% et les coefficients de corrélation de Pearson sont très élevés, supérieurs à 0,80. Les performances en calage et en validation sont du même ordre de grandeur, mais celles en validation semblent légèrement supérieures à celles obtenues en calage. Au vu des valeurs des critères de performance consignées dans le *Tableau.1*, le modèle PMCD3p ayant comme variables d'entrée la pluie, l'ETP et le débit, est plus performant.

Tableau 1 : Performance des réseaux de neurones développés

Réseaux de neurones	Entrées des modèles	Calage		Validation	
		Nash-Sutcliffe (%)	R	Nash-Sutcliffe (%)	R
PMCD1 _p	Pluie + Débit	72	0,88	77	0,89
PMCD3 _p	Pluie+ETP+débit	74	0,91	79	0,90
PMCD4 _p	Pluie+Température+débit	73,6	0,88	78,2	0,89

Le critère de robustesse évalué à partir de la différence entre la performance en calage et celle en validation au moyen du critère de Nash-Sutcliffe est de 5% pour les modèles PMCD1p et PMCD3_p. Quant au modèle PMCD4_p, il a enregistré une valeur de 4,6%. Toutes les valeurs enregistrées sont inférieures à 10%, mais le résultat le plus satisfaisant a été obtenu avec le modèle PMCD4P. Les **Figures 7 à 9** représentent les hydrogrammes mesurés et calculés respectivement pour les modèles PMCD1p, PMCD3p, PMCD4p. L'analyse de ces hydrogrammes montre bien que les modèles de prévision développés reproduisent très bien la dynamique des écoulements du Bandama Blanc à la station hydrométrique de Tortiya. On peut cependant, remarquer quelques décalages entre les débits mesurés et les débits calculés par ces modèles.

En effet, ces hydrogrammes montrent que tous les modèles sous-estiment au moins 2/3 des débits de pointes mesurés au mois de septembre qui correspond au mois des débits de crues. Les mois de septembre des années suivantes sont concernés par cette remarque : (i) 1989, 1991, 1994 et 19 97, avec le modèle PMCD1p ; (ii) 1989 et 1991, avec les modèles PMCD3p, PMCD4p. Ces observations permettent de constater que l'ajout des variables explicatives, comme la température, l'évapotranspiration améliore la capacité des réseaux de neuronaux à calculer les débits mensuels du Bandama à la station de Tortiya.

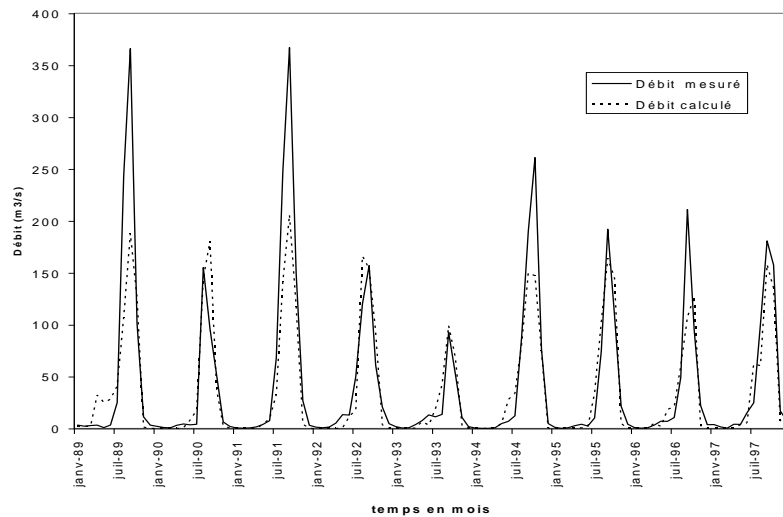


Figure 7 : Hydrogrammes mesuré et calculé en validation par le modèle neuronal PMCD1_p

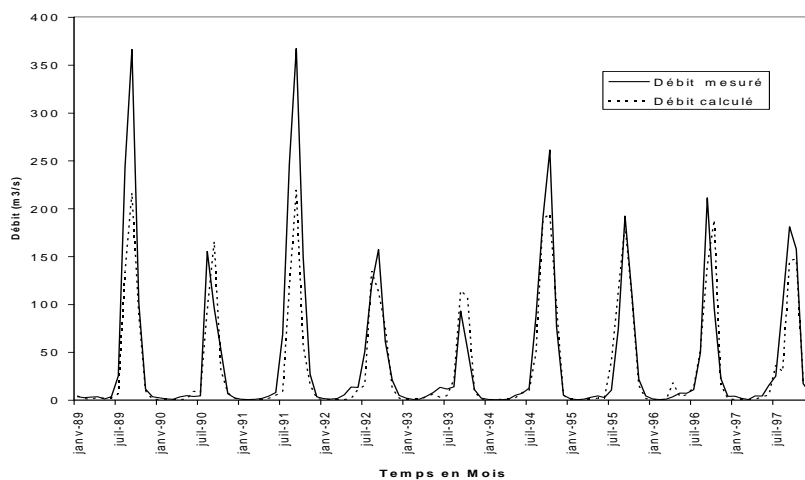


Figure 8 : Hydrogrammes mesuré et calculé en validation par le modèle neuronal PMCD3_p

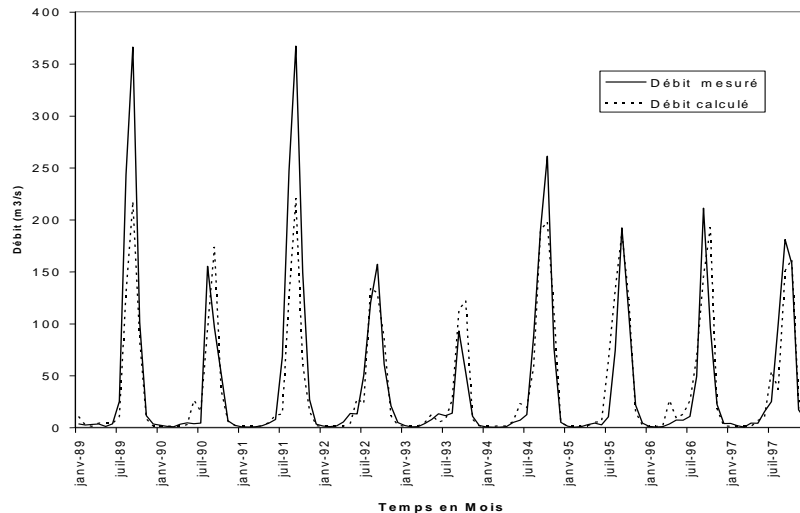


Figure 9 : Hydrogrammes mesuré et calculé en validation par le modèle neuronal PMCD4_p

5. Discussion

Les modèles développés dans ce travail expriment plus de 70% de la variation des débits du Bandama Blanc à Tortiya. Les résultats obtenus montrent que le modèle PMCD3p est plus performant que le modèle PMCD4p qui est plus performant que le modèle PMCD1p. En effet, en se référant aux variables d'entrée de ces différents modèles, le modèle le plus performant (PMCD3p) a en entrée toutes les variables essentielles à la détermination du débit à l'exutoire d'un bassin versant, à savoir la pluie (apport d'eau sur le bassin d'étude) et l'évapotranspiration potentielle (ETP) (perte d'eau sur le bassin d'étude). Toujours par rapport aux données d'entrée, le modèle PMCD3p englobe les deux autres modèles ; car, le calcul de l'ETP fait intervenir la température (l'une des entrées du modèle PMCD4p).

Plusieurs travaux [26] ont montré que l'ETP influence plus les oscillations journalières du débit d'une rivière que les eaux souterraines qui sortent du bassin versant considéré. Malgré ces bonnes performances de ces modèles, les débits extrêmes sont mal estimés. En effet, les Réseaux de neurones Formels sont des modèles à apprentissage, c'est-à-dire qu'ils se familiarisent aux données pendant le calage afin d'extraire une certaine singularité dans ces données. Ces décalages pourraient donc être le fait du nombre réduit de données utilisées pendant l'apprentissage (18 mois) de ces modèles de prévision. En fait, par rapport au pas de temps mensuel considéré dans cette étude, les débits extrêmes (crue et étiages) sont en nombre restreint par rapport aux autres débits. Les crues par exemple s'observent une seule fois par année (généralement en août-septembre). Il apparaît donc clairement que les modèles ne disposent pas suffisamment de débits de cette catégorie en apprentissage pour pouvoir extraire cette singularité.

Des études similaires ont montré que, plus on dispose de données pour l'apprentissage et plus les modèles reproduiraient fidèlement les débits. Parmi ces études, on peut citer celles de [27] sur la prévision des débits de la rivière Apalachicola (Floride, USA) avec les Réseaux de neurones Artificiels. En effet, ces auteurs ont fait la prévision des débits à plusieurs pas de temps (temps journalier, mensuel, trimestriel et annuel) et ont obtenu des coefficients de corrélation de Pearson respectives de 0,98 ; 0,95 ; 0,91 et 0,83. L'analyse de ces performances montre que plus le pas de temps considéré est petit, ce qui est équivalent à un nombre élevé de données, les modèles de prévision développés apparaissent plus performants. Les travaux de [18] ont aussi permis de conclure que plus les données en entrée des réseaux de neurones sont nombreuses et plus ces modèles sont performants.

La mauvaise prévision des débits extrêmes par les réseaux de neurones dans cette étude pourrait être aussi due à la séparation des bases de calage et de validation (2/3 pour le calage et 1/3 pour la validation). Une séparation aléatoire pourrait peut être améliorer les performances de ces modèles.

6. Conclusion

Les résultats obtenus avec les modèles de prévision sont satisfaisants dans l'ensemble. En effet, en se référant à l'échelle de Kachroo on se rend compte que les modèles développés sont très performants ; car, les critères de Nash-Sutcliffe sont supérieurs à 70% en calage et en validation. Le maximum des Nash-Sutcliffe est de 74 en calage et de 79 en validation ; et le minimum est de 71,6% en calage et de 77% en validation. Au niveau des coefficients de corrélation de Pearson, la valeur maximale en calage est de 0,91 et de 0,90 en validation ; et la valeur minimum est de 0,86 en calage et de 0,89 en validation. Le critère de robustesse évalué est de 5% pour les modèles PMCD1_p et PMCD3_p. Quant au modèle PMCD4_p, il a enregistré une valeur de 4,6%. Toutes les valeurs enregistrées sont inférieures à 10%. Les différents modèles sont très robustes donc stables dans l'ensemble. Malgré les bonnes performances des modèles Perceptrons Multicouches en prévision, les débits extrêmes étaient mal modélisés. En effet, les débits de pointes extrêmes (les débits de crue) sont dans leur majeure partie sous-estimés et les débits d'étiages extrêmes sont quant à eux surestimés. Il est aussi apparu dans cette étude que pour la prévision, les modèles neuronaux développés sont des modèles très simples.

En effet, un Perceptron Multicouches, avec une seule couche cachée et quelques neurones suffisent pour faire la prévision des débits du Bandama Blanc, avec de très bonnes performances. Le nombre de neurones sur les couches cachées des réseaux développés sont de : (i) 3 neurones pour les modèles PMCD1_p et PMCD4_p ; (ii) 5 neurones pour le modèle PMCD3_p. Aussi, faudrait-il noter que cette étude a permis d'apprécier l'apport des variables telles que la température, l'évapotranspiration et le mois ainsi que leurs combinaisons dans la prévision des débits mensuels du Bandama Blanc. Il ressort de cette étude que la pluie et l'évapotranspiration potentielle sont suffisantes comme données d'entrée des Perceptrons Multicouches Dirigés pour faire la prévision des débits mensuels du Bandama Blanc à la station de Tortiya dans un contexte de non-linéarité de la relation pluie-débit.

Références

- [1] - J. EL-JABI et N. ROUSSELLE, "Hydrologie fondamentale", Ecole Polytechnique de Montréal, Canada (1987) 234
- [2] - Y. B. KOFFI, "Modélisation pluie-débit en région tropicale humide : application des réseaux de neurones sur quatre stations hydrométriques du Bandama Blanc (Bada, Marabadiassa, Tortiya et Bou) situées au Nord de la Côte d'Ivoire". Thèse unique d'hydrogéologie, Université de Cocody Abidjan (2007) 219
- [3] - H.WENRI, B. XU, and C. H. AMY, "Forecasting flows in Apalachicola river using neural networks". Hydrological Processes, Vol. 18 (2004), 2545-2564
- [4] - A. JOHANNET, "Les réseaux de neurones formels". Cours, Travaux dirigés et travaux pratiques. Ecole des Mines d'Alès, Alès, France (2006) 54
- [5] - P. A. AYRAL, "Contribution à la spatialisation du modèle de prévision des crues éclairées ALHTAIR. Approche spatiale et expérimentale, application au bassin versant du Gardon d'Anduze". Thèse de Doctorat, Université de Provence, Aix-Marseille 1, LGEI, Ecole des Mines d'Alès, Alès, France (2005) 311

- [6] - N. DECHEMI, B. A. TARIK et A. ISSOLAH, "Modélisation des débits mensuels par les modèles conceptuels et les systèmes neuro-flous". *Revue des Sciences de l'Eau*. Vol. 16 n°4 (2003) 407-424
- [7] - B. A. TARIK et N. DECHEMI, "Modélisation pluie—débit journalière par des modèles conceptuels et "boîte noire"; test d'un modèle neuroflou / Daily rainfall—runoff modelling using conceptual and black box models; testing a neuro-fuzzy model". *Journal des Sciences Hydrologiques*, Vol. 49 (2004) 919-930
- [8] - V. KLEMES, "Operational testing of hydrological simulation models". *Journal des sciences hydrologiques*, Vol. 31 (1986a) 13-24
- [9] - P. COULIBALY, F. ANCTIL, et B. BOBEE, "Prévision hydrologique par réseaux de neurones artificiels : Etat de l'art". *Revue canadienne de génie civil*, Vol. 26 (1999) 293-304
- [10] - W. JAMES, "The Principles of Psychology". Vol. 1 (1890) 689
- [11] - W. S. McCulloch et W. Pitts, "A logical calculus ideas immanent in nervous activity". *Bulletin of Mathematical Biophysics*, Vol. 5 (1943) 115-133
- [12] - D. HEBB, "The Organization of Behavior: A Neuropsychological Theory"(1949) 378
- [13] - F. ROSENBLATT, "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain". *Psychological Review*, Vol. 65, No. 6 (1958) 386-408
- [14] - J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities". *Proceedings of the National Academy of Sciences USA*, Vol. 79, No. 8 (1982) 2554-2558
- [15] - P. J. WERBOS, "Applications of advances in nonlinear sensitivity analysis". *System modeling and optimization*. Drenick R. et Kozin F. Springer-Verlag, New York (1981) 762-770.
- [16] - C. TOUZET, "Les réseaux de neurones artificiels. Introduction au connexionnisme". *Cours, exercice et travaux pratiques* (1992) 58
- [17] - V. FORTIN, T. B. M. J. OURDA, P.F. RASMUSSEN, et B. BOBEE, "Revue bibliographique des méthodes de prévision des débits". *Revue des sciences de l'eau*, Vol.10, n°4 (1997) 461-487
- [18] - N. R. RIJA, P. LAURET, Z. A. RANDRIAMANANTANY et J. C. GATINA "Modélisation du régime annuel des petites rivières en vue d'installation de microcentrales hydroélectriques", *Afrique Science*, 05(1) (2009) 39- 49
- [19] - G. DREYFUS, J. M. MARTINEZ, M. SAMUELIDES, GORDON, M. B, BADRAN, F., S. THIRIA, et L. HERAULT, "Réseaux de neurones : Méthodologie et application". 2^{ème} édition, Groupe Eyrolles (2004) 374
- [20] - A. G. AWADALLAH, "Hydro-climatologie globale pour la prévision des crues du Nil au moyen de fonction de transfert avec bruit et de Réseaux de neurones Artificiels". *Thèse de Doctorat, Université de Montréal, Québec, Canada* (1999) 220
- [21] - W. S. SARLE, "Neural network FAQ, Introduction, periodic posting to the Usenet newsgroup comp.ai.neural-nets (1999) 1-7
- [22] - J. E. NASH, et J. V. STUCLIFFE, "River flow forecasting through conceptual models. Part 1. A discussion of principles". *Journal of Hydrology*, Vol. 10 (1970) 282-290
- [23] - R. K. KACHROO, "HOMS workshop on river flow forecasting", Nanjing, China. Unpublished internal report, Dep. Eng. Hydrol., University College Galway, Irelan (1986) 149
- [24] - X. LEGATES, and J. MCCABE, "Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation". *Water Resources Research*, Vol. 35, n°1 (1999) 233-241
- [25] - A.M. KOUASSI, K.F. KOUAME, Y.B KOFFY, K.A. KOUAME, S. OULARES J. BIEMI, "Modélisation des débits mensuels par un modèle conceptuel : application à la caractérisation de la relation pluie-débit dans le bassin versant du N'zi-Bandama (Côte d'Ivoire) ". *Journal Africain de Communication Scientifique et Technologique*, N°11 (2011) 1377-1391.
- [26] - J. CALLEDE, "Oscillation journalière du débit des rivières en l'absence de précipitation", *Cah. ORTOM, Sér., Hydrol.*, vol. XIV, n°3 (1977) 219-283