

## CLUSTERISATION MENSUELLE POUR LA MODELISATION DU TRANSPORT DES SEDIMENTS PAR HYBRIDATION DES RESEAUX DE NEURONES ARTIFICIELS (RNA) AVEC LE SYSTEME D'INFERENCE FLOUE (SIF).

### MONTHLY CLUSTERING FOR SEDIMENT TRANSPORT MODELING BASED ON HYBRIDIZATION OF ARTIFICIAL NEURAL NETWORK (ANN) WITH A FUZZY INFERENCE SYSTEM (FIS).

S. BENGHERIFA <sup>(1)</sup>, A. LEFKIR <sup>(2)</sup>, A. BERMAD <sup>(1)</sup>

<sup>1</sup>ENP d'Alger, 10, avenue Hassen Badi, B.P.16182, El Harrach, Alger, Algérie

<sup>2</sup>ENSTP, Laboratoire de TPiTE, BP 32, Vieux Kouba, Alger, Algérie

---

réception : 01/12/2016

acceptation : 30/12/2017

publication : 30/06/2018

---

**Résumé** - Une identification des différents paramètres caractérisant le processus d'érosion ainsi que leurs lois de variation est nécessaire pour la compréhension ainsi que la prévision de ce phénomène. Deux modèles ont été testés : l'un empirique et l'autre basé sur la logique floue utilisant un apprentissage neuronal à partir des débits observés en amont du barrage de Beni Amrane très vulnérable aux transports solides. Il est à noter que le modèle flou (à apprentissage neuronal) utilise une architecture complexe et cela contrairement à la simplicité du modèle empirique. En effet, le modèle flou est optimisé avec un nombre de règles variant de 5 à 13 règles et paraît plus robuste que le modèle empirique utilisant deux paramètres. Ce travail a donc pour objectif la contribution effective dans la modélisation du transport solide par l'amélioration des performances des modèles neuro-flous en introduisant un nouveau concept appelé apprentissage mensuel. Ce dernier repose sur l'hypothèse que les paramètres hydro-climatiques du même mois sont semblables chaque année.

Mots clés : érosion, transport solide, modèle empirique, RNA, SIF, apprentissage mensuel.

**Abstract** - The identification of the various parameters characterizing the erosion process as well as their laws of variation is necessary for both understanding and predicting of this phenomenon. Two models were tested in this study, one empirical and the other based on fuzzy logic using neuronal learning from the observed flows of Beni Amrane dam. The fuzzy model uses a complex architecture, contrary to the simplicity of the empirical model. Indeed, the fuzzy model is optimized with a number of rules varying from 5 to 13 rules, and it seems more robust than the empirical model using only two parameters. The objective of this study is to improve the performance of fuzzy models by introducing the new concept of monthly learning process in fuzzy model.

Key-words: erosion, suspended sediment, empirical model, ANN, FIS, monthly apprenticeship

## Introduction

L'impact du phénomène d'érosion, au niveau d'un bassin versant, est néfaste sur l'environnement que ce soit en amont par la dégradation des sols arables qu'en aval par le phénomène d'envasement des barrages en passant par le sapement des berges au niveau des cours d'eaux.

L'érosion peut être examinée tant du point de vue du transport des sédiments que du point de vue de l'ablation des particules de sol. En effet, la première approche tente de prédire la charge sédimentaire à l'exutoire des cours d'eau tandis que la seconde approche estime les taux de production de sédiments à la source, c'est-à-dire les taux d'ablation sur les versants.

La technique la plus simple pour étudier l'ampleur des processus d'érosion consiste à mesurer les concentrations de sédiments dans les cours d'eau. L'échantillonnage collecte non seulement les particules provenant de l'érosion des sols mais également celles produites par l'érosion des berges. Ainsi, le terme « transport solide » englobe l'ensemble des particules transportées par un cours d'eau.

De nombreux modèles existent pour simuler les processus physiques déterminant la quantité de matières en suspension résultant d'un débit liquide. Les modèles débit liquide- débit solide sont utilisés pour décrire le comportement hydrologique d'un bassin versant.

Deux approches ont été effectuées. La première approche est basée sur les modèles régressifs, tandis que la deuxième est basée sur un des concepts de l'intelligence artificielle : il s'agit de la logique floue associée à la théorie des réseaux de neurones artificiels.

## Matériels et méthodes

### Description de la zone d'étude

La zone d'étude concerne le bassin versant de l'Isser situé au nord de l'Algérie. Ce bassin versant est situé à environ 70 Km au Sud Est d'Alger et draine une superficie de 4 170 km<sup>2</sup> et se situe entre les latitudes 35°90' et 36°85' Nord et les longitudes 2°88' et 3°95'.

Les principales caractéristiques climatiques influençant le processus d'érosion sont la température, la pluviométrie et l'humidité. La température moyenne annuelle est de 17°C, pour les mois les plus froids elle varie entre 5°C et 6°C et entre 27°C et 31°C pour les plus chauds. Le régime pluviométrique (entre 700 et 800 mm annuel) se caractérise par des pluies abondantes, concentrées surtout en hiver (140 mm en décembre), qui diminuent presque régulièrement au printemps et atteignent en été quelques millimètres par mois. L'humidité est modérée pendant toute l'année avec des valeurs d'environ 70% le matin et le soir en été et de 80% en hiver ; les valeurs à midi sont d'environ 57% en avril et octobre, 60% en été et 64% en hiver. L'humidité moyenne de l'air varie entre 72% en été et 80% en hiver.

Le réseau de mesures hydrométriques de l'oued Isser et ses affluents, implanté et géré par l'ANRH, est équipé d'un réseau de sept stations de jaugeage : El Omaria (091205), Dechmia (090309), Beni Slimane (090305), Mezahim (030191), Aoamar Gare (090416), Pont de la Traille (090408) et Lakhdaria (090501).

## Modélisation transport solide

### A) Modèle empirique

Les modèles classiques de régression ont pour but d'exprimer la variation du débit solide en fonction du débit liquide. Il existe plusieurs approches de régressions (régression linéaire, polynomiale, logarithmique, exponentielle et régression en puissance). Ces modèles montrent l'orientation commune de la série de couples débit liquide – débit solide. La tendance obtenue peut être exprimée mathématiquement sous forme d'équation (formule empirique).

### B) Modèle neuro-flou

La modélisation d'un système entrée/sortie par la logique floue s'effectue en trois phases essentielles :

La fuzzification transforme la variable modélisée en une partie floue. La fuzzification permet de modéliser les entrées d'un système principalement sous forme de courbes appelées fonctions d'appartenance. Ces dernières permettent de délimiter les sous-ensembles flous. Elles représentent le degré d'appartenance d'une valeur à un état donné et peuvent avoir différentes formes (en triangle, en trapèze, etc.). Les séries de débits liquides et de débits solides sont ainsi divisées en un nombre équivalent de sous-ensembles flous (partitionnement flou).

L'inférence floue produit l'image de la partie floue issue de la fuzzification par une relation floue construite à partir des règles floues. À la présentation de chaque entrée (valeur de débit) en fonction des règles d'inférence floue, on détermine le degré d'appartenance à un sous-ensemble donné. Les systèmes d'inférence floue (SIF) permettent de modéliser la plupart des applications continues d'un espace à  $n$  dimensions dans  $\mathcal{R}$ . A la différence des modèles mathématiques ou des modèles de type "boîte noire", la représentation est faite en langage naturel, sous la forme de règles *Si ... Alors*.

La défuzzification transforme la partie floue issue de l'inférence en une valeur numérique de sortie et peut être effectuée par plusieurs méthodes. Dans notre cas, nous avons utilisé la technique du centre de gravité : la valeur simulée (concentration en MES) correspond à la projection du centre de gravité (défuzzification centroïde) de la surface d'inférence sur l'abscisse de la série des concentrations observées.

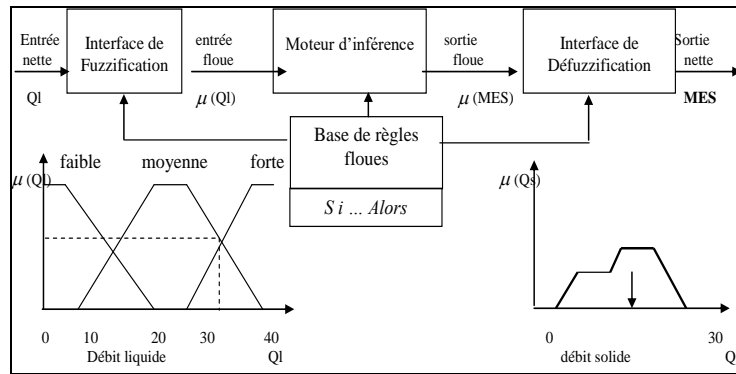


Figure-1 : Structure d'un System d'Inférence Flou  
Figure-1 : Structure of fuzzy inference system

La description précédente caractérise le modèle flou de type SUGENO (1985). Dans ce modèle, la prémisse est symbolique mais la conclusion est une procédure donnant directement une valeur de la variable modélisée, soit par une fonction linéaire (modèle d'ordre 1), soit par des constantes (modèle d'ordre 0). Le modèle utilisé est un modèle neuroflou, qui utilise la logique floue et une structure neuronale à apprentissage supervisé (JANG, 1993) qui permet l'estimation des paramètres non linéaires (de prémisse).

Les modèles neuroflous développés pour simuler le débit solide sont calibrés durant une période dite de calage pour estimer les paramètres des modèles. Leurs performances seront testées en période de validation pour valoriser la capacité prédictive de ces modèles.

Le premier modèle consiste à simuler les débits solides par apprentissage annuel de la période de calage. Les données de l'apprentissage annuel sont ainsi constituées par fusion de l'éventail des données annuelles de la période de calage. Le deuxième modèle consiste à simuler les débits solides à l'échelle annuelle par un apprentissage mensuel de chaque mois constituant la période de validation. Les données de l'apprentissage mensuel sont constituées par fusion de l'ensemble de données mensuelles dans l'éventail des données de calage. La Figure 2 illustre l'ensemble des procédures développées.

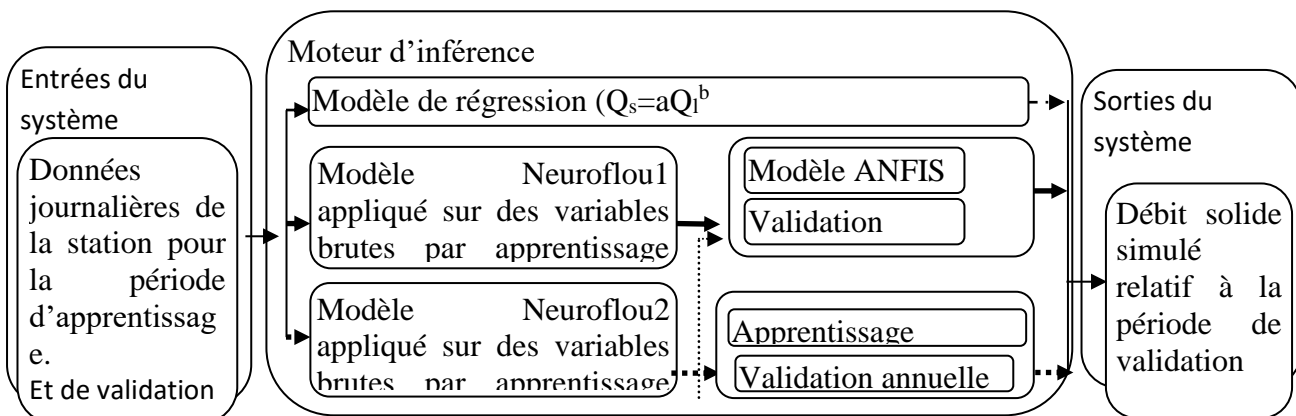


Figure-2 : Ordinogramme des procédures de simulation débit liquide, débit solide par les modèles neuro-flous.

Figure-2: Flow chart of liquid flow-solid flow simulation procedures by neuro-fuzzy models.

### C) Validation des modèles utilisés

L'évaluation d'un modèle consiste à comparer les valeurs simulées aux valeurs observées. En plus d'une analyse subjective des chroniques simulées comparées aux chroniques observées, des critères statistiques objectifs sont utilisés pour caractériser globalement la qualité de la simulation. Dans ce travail, nous avons utilisé les critères classiques en hydrologie : biais, corrélation, et critère de Nash. Le critère de Nash exprime, en pourcentage, le rapport entre l'erreur relative aux valeurs simulées et observées avec la fluctuation des valeurs observées par rapport à la moyenne.

Les paramètres linéaires de validation sont ajustés par la méthode des moindres carrés.

$$Nash = 1 - \frac{\sum_{i=1}^{n_{obs}} (Y_{i\ mod} - Y_{i\ obs})^2}{\sum_{i=1}^{n_{obs}} (Y_{i\ obs} - \bar{Y}_{obs})^2} \quad (1)$$

$Y_{i\ mod}$  et  $Y_{i\ obs}$  représentent respectivement les flux observés et simulés à l'instant  $i$ ,  $Y_{moy}$  est la moyenne des flux observés. Si la valeur du critère de Nash converge vers cent, le modèle est optimisé. L'erreur sur le bilan est exprimée en pourcentage, l'erreur sur le bilan est calculée comme suit :

$$E = \frac{\sum_{i=1}^{n_{obs}} (Y_{i\ obs} - Y_{i\ mod})}{\sum_{i=1}^{n_{obs}} (Y_{i\ obs})} \quad (2)$$

Le coefficient de corrélation s'exprime par :

$$R = \frac{\sqrt{\sum_{i=1}^n ((Y_{i\ obs} - \bar{Y}_{obs}) \times (Y_{i\ mod} - \bar{Y}_{mod}))^2}}{\sqrt{\sum_{i=1}^n (Y_{i\ obs} - \bar{Y}_{obs})^2 \times \sum_{i=1}^n (Y_{i\ mod} - \bar{Y}_{mod})^2}} \quad (3)$$

## Résultats et discussions

### A) échelle mensuelle au pas de temps journalier

La simulation des débits solides en suspension au pas de temps journalier présente un grand intérêt du fait qu'elle permet d'anticiper l'évolution de l'envasement des barrages à partir des données hydrométriques journalières. Cette simulation est tributaire de la taille des séries de données utilisées et de leur qualité.

Concernant les données à l'échelle mensuelle au pas de temps journalier, nous avons choisi, pour la validation des modèles développées, quatre périodes d'observation débit-MES de la station de Lakhdaria (090501). Il s'agit des mois de janvier, février, Mars et mai de l'année 1987. La période d'apprentissage est composée d'un cumul de données enregistrées au mois correspondant pendant les années d'apprentissage (1984-1986). La période du mois de janvier 1987, par exemple, correspond aux données journalières enregistrées pendant tous le mois de janvier 1987, la durée d'apprentissage de 93 jours, correspond au cumul de données journalières enregistrées le mois de janvier des années (1984-1986).

Tableau-1 : Résultats des modèles en période de calage et en période de validation.

Table-1: Results of calibration period and validation period.

Modèle		Période de calage				Période de validation					
		Empirique		Flou		Empirique			Flou		
Période	Durée(j)	Nash(%)	E(%)	Nash(%)	E(%)	Nash(%)	E(%)	R(%)	Nash(%)	E(%)	R(%)
Jan-87	93	-95.92	166	71.79	0.37	21.84	155	80.31	98.76	0.7	99.42
Fév-87	84	-5.64	0.235	97.30	9.84	72.08	39.49	90.67	98.67	7.13	99.43
Mar-87	93	-211.9	208	93.92	0.73	-1428	1839	88.42	87.17	12.1	93.69
Mai-89	93	-473.52	354	89.17	3.5E-4	7.71	34.44	63.98	71.47	0.002	84.55

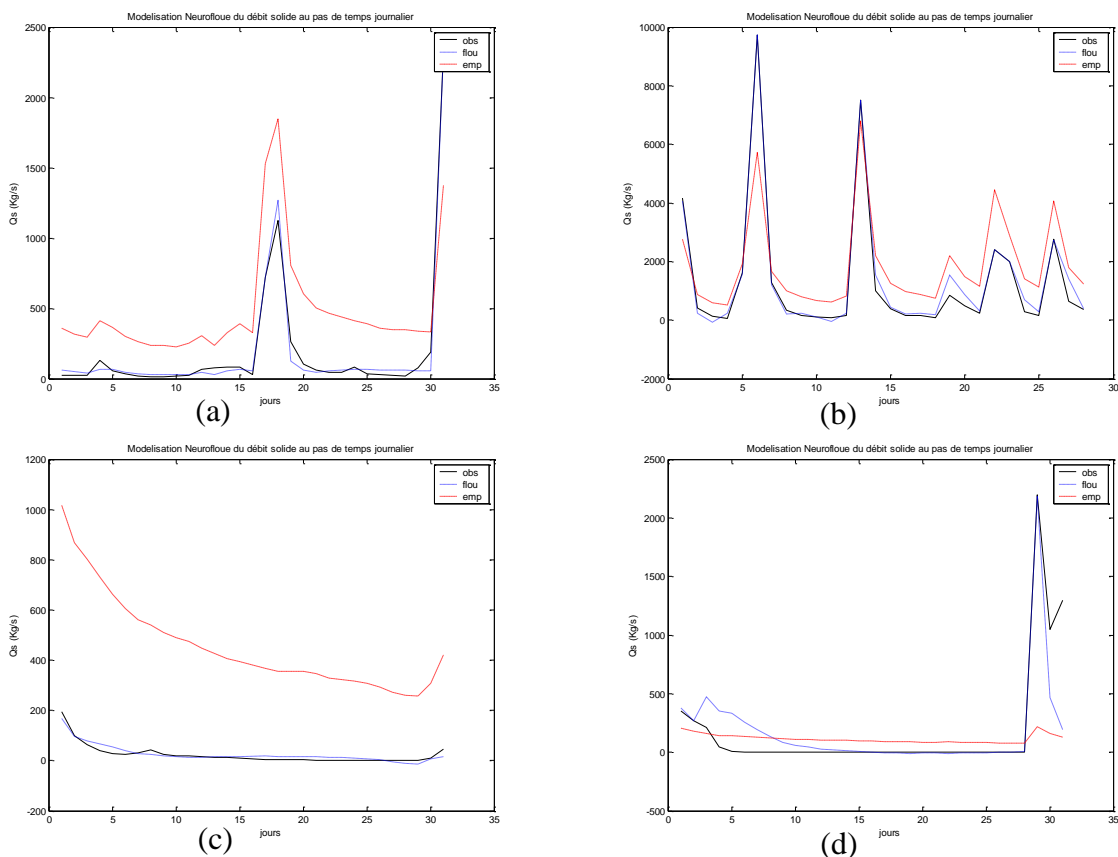


Figure- 3 :Variation du débit solide au pas de temps journalier.  
Figure-3: Variation of the solid flow at the daily time step.

Le modèle flou a donné des résultats très performants à cette échelle (tableau 1). En effet, en période de calage, le critère de Nash est souvent supérieur à 90 % sauf pour le mois de janvier 1987 où le critère de Nash est de 71,8%. L'erreur sur le bilan ne dépasse pas 9,8%. En période de validation, le critère de Nash est supérieur à 87% excepté le mois de mai 1989 où le critère de Nash est de 71.5%. Notons que ce critère dépasse les 98% pour les périodes humides (janvier et février 1987). L'erreur sur le bilan est relativement faible et ne dépasse pas 12 %. Le coefficient de corrélation pour la majorité des épisodes est supérieur à 93% sauf au mois de mai 1989 où le coefficient de corrélation est de 84,5%.

Pour le modèle empirique, les résultats obtenus sont médiocres en période de validation qu'en période de calage. La valeur du critère de Nash pour la période d'apprentissage sont toutes négatives, pour les valeurs de l'erreur elles sont complètement erronées. En période de validation, le critère de Nash est inférieur à 72% et il atteint -1428 pour le mois de Mars 1987. Les valeurs de l'erreur sont supérieures à 44% et elles arrivent jusqu'à 1839%. Les valeurs des coefficients de corrélation obtenues par le modèle empirique en période de validation sont supérieures à 80% excepté le mois de Mai 1989 où la valeur atteint 63%.

Notons aussi que pour le modèle flou, une reproduction meilleure des valeurs du débit solide durant les périodes humides que dans les périodes sèches. Tandis que le modèle empirique surestime les valeurs du débit solide autant en période humide qu'en période sèche. Notons, à titre d'exemple, que pour le mois de mars 1987, le pic du débit solide observé est de l'ordre de 200 (Kg/s) tandis que la valeur estimée est de l'ordre de 1000 (Kg/s).

On remarque donc que pour les mois où la fluctuation journalière du débit solide est très importante, le modèle neuro-flou donne de meilleures valeurs des critères de validité. En effet, le critère de Nash dépasse les 98.7 % pour les périodes humides (mois de janvier et mois de février) tandis qu'il est relativement faible pour les périodes sèches soit 71.47% pour le mois de mai de l'année 1989. On conclut que le modèle donne une bonne approximation dans la période de forte fluctuation de débit par rapport aux périodes de faibles fluctuations. Autrement dit, la robustesse du modèle neuro-flou ainsi développé apparaît mieux lors du déclenchement d'un événement hydrologique, là où le phénomène d'érosion se manifeste.

## **B) Echelle annuelle au pas de temps journalier**

La simulation a été faite à partir des données de la période comprise entre janvier 1984 et juillet 1989. L'objectif principal est de tester les modèles sur un éventail de données relativement court, pour étudier le pouvoir prédictif de ces modèles. Nous avons choisi, pour la période de validation des modèles développées à cette échelle, deux années d'observation de la station de Lakhdaria (090501). Il s'agit des années 1974 et 1975.

Pour l'apprentissage, à cette échelle, nous avons développé deux concepts distincts. Le premier, appelé, conventionnellement, Apprentissage Annuel, consiste à construire les années d'apprentissage année par année en considérant l'éventail de données de la période de calage. En effet, la période d'apprentissage est composée, tout simplement, d'un cumul de données enregistrées entre 1984 et 1986.



Le deuxième, appelé Apprentissage Mensuel, consiste à construire les valeurs des débits solides simulés par assemblages de douze mois de l'année de validation simulée à une échelle mensuelle. L'apprentissage d'un mois quelconque est composé d'un cumul de

données enregistrées au mois correspondant pendant les années d'apprentissage. Les valeurs d'apprentissage du mois de janvier, par exemple, correspondent, donc, à l'assemblage de toutes les valeurs mesurées au mois de janvier pendant les années d'apprentissage (1984-1989).

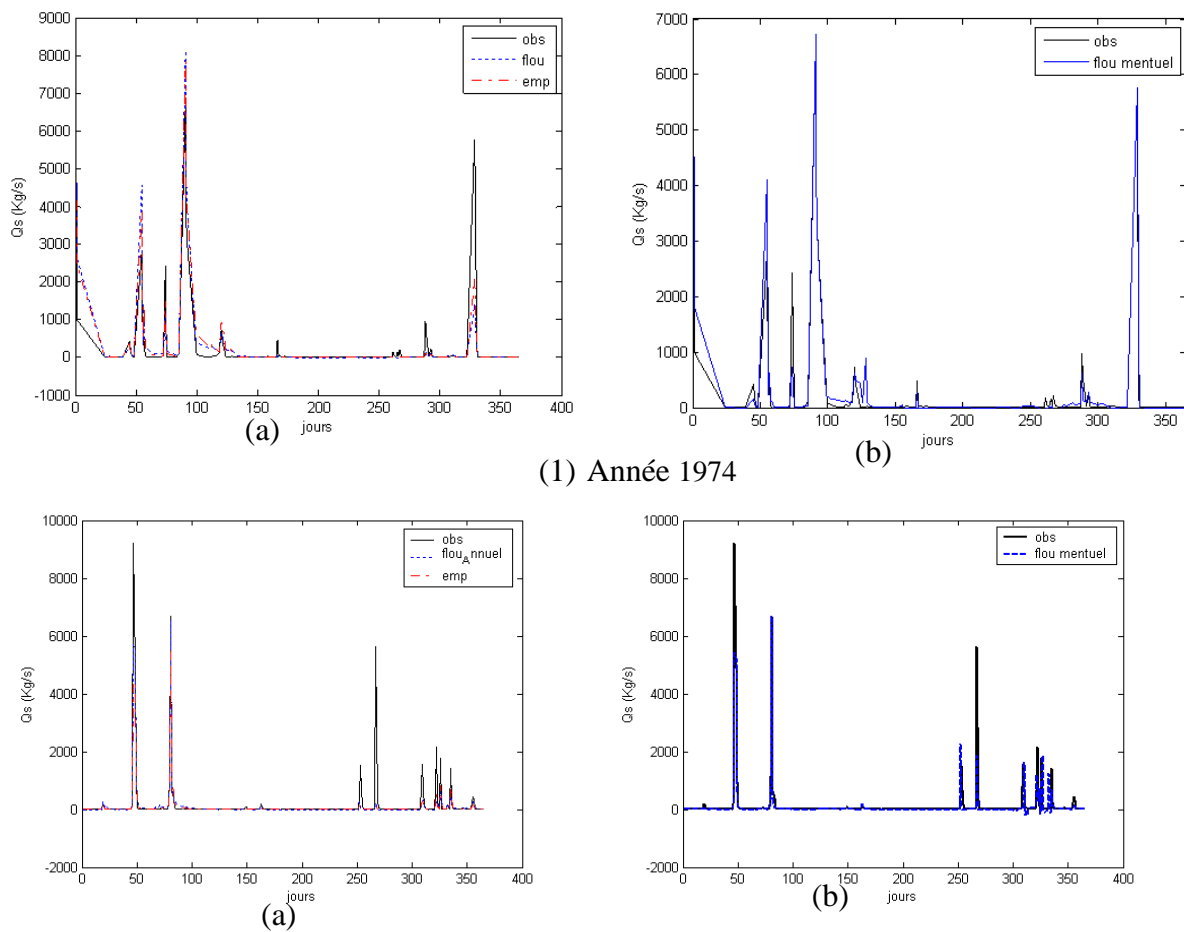
Tableau- 2 : Résultats des modèles en période de calage et en période de validation.  
Table-2 : Results of models during the calibration and validations periods.

Modèle	Période de calage				Période de validation								
	Empirique		Flou Annuel		Empirique			Flou Annuel			Flou Mensuel		
Période	Nash(%)	E(%)	Nash(%)	E(%)	Nash(%)	E(%)	R(%)	Nash(%)	E(%)	R(%)	Nash(%)	E(%)	R(%)
1974	36.59	9	43.67	2.36	39.86	18.5	63.34	63.5	29.05	66.85	94,56	3,83	87.09
1975	36.59	9	43.94	1.51	65.01	42.41	84.99	70.7	35.79	85.34	74.68	29.9	87.27

Il est à remarquer que le modèle neuro-flou à apprentissage annuel a effectivement donné de résultats relativement bons par rapport au modèle empirique, mais le modèle neuro-flou à apprentissage mensuel donne des résultats meilleurs. En effet, le critère de Nash obtenu en période de validation par le premier modèle est de 94.56% pour l'année 1974, tandis que le modèle neuro-flou à apprentissage annuel et le modèle empirique ont donné respectivement 63.57% et 39.86%. En période de validation, les pics des MES sont parfois bien simulés et l'erreur sur le bilan est moyenne (Figure 5).

Pour le modèle empirique, les résultats obtenus sont médiocres aussi bien en période de validation qu'en période de calage. Les valeurs du critère de Nash pour la période d'apprentissage sont inférieures à 36,5%, pour les valeurs de l'erreur elles sont relativement faibles (9%). En période de validation, la valeur du critère de Nash est comprise entre 39% et 65%. Les valeurs de l'erreur sont comprises entre 18% et 42%. Les valeurs des coefficients de corrélation obtenues par le modèle empirique en période de validation sont comprises entre 63% et 85%.





(1) Année 1974

(2) Année 1975

Figure- 4 : Variation du débit solide au pas de temps journalier (a)Flou annuel (b) Flou mensuel

Figure-4 : Variation of solid flow at the daily time step (a) annual fuzzy (b) Monthly fuzzy

Pour le modèle flou\_annuel, les résultats obtenus sont mauvais mais relativement meilleurs que ceux obtenus par le modèle empirique. En effet, Les valeurs du critère de Nash pour la période d'apprentissage sont inférieures à 43,9% , pour les valeurs de l'erreur elles sont relativement faibles, elles sont inférieures à 2.3%. En période de validation, la valeur du critère de Nash est comprise entre 63,5% et 70,7%, soit une moyenne de 67%. Les valeurs de l'erreur sont comprises entre 29% et 36%, soit une moyenne de 32%. Les valeurs des coefficients de corrélation obtenues par ce modèle en période de validation sont comprises entre à 66% et 85%.

Le modèle flou\_mensuel, a donné des résultats relativement bons comparés à ceux obtenus par les deux modèles cités précédemment. En effet, la valeur du critère de Nash est comprise entre 75% et 94,5%, soit une moyenne de 85%. L'erreur sur le bilan est comprise entre 3,8% et 29%, soit une moyenne de 16%. Le coefficient de corrélation pour les deux années est proche de 87%. On remarque que pour la même valeur du coefficient de corrélation, on peut avoir des valeurs des critères de Nash et de l'erreur différentes, ce qui confirme l'indisponibilité d'associer les trois critères pour la validation d'un modèle.

Notons aussi que le modèle flou\_mensuel donne une reproduction meilleure des valeurs du débit solide comparé au modèle flou\_annuel .

En comparant les résultats des modèles en fonction des échelles temporelles, nous pouvons noter la complexité de la relation débit-MES au pas de temps journalier. En effet, si à l'échelle horaire la non-linéarité constitue la grande difficulté de simulation, au pas de temps journalier, le modèle se trouve confronté à des cas difficilement modélisables (ex. : débit élevé, concentration MES faible, débit faible, concentration MES élevée). Néanmoins, les résultats obtenus par l'approche floue sont satisfaisants.

## Conclusions

En comparant les résultats des modèles en fonction des échelles temporelles, nous pouvons noter la complexité de la relation débit-MES à l'échelle annuelle au pas de temps journalier. En effet, si au pas de temps horaire la non-linéarité constitue la grande difficulté de simulation, au pas de temps journalier, le modèle se trouve confronté à des cas difficilement modélisables (exemple : débit élevé, concentration MES faible, débit faible, concentration MES élevée). Néanmoins, les résultats obtenus par l'approche floue sont satisfaisants.

On remarque aussi qu'à l'échelle mensuel au pas de temps journalier, les valeurs de l'erreur sur le bilan sont meilleures que celles de l'échelle annuelle. Soit une valeur moyenne de l'erreur de 5% pour l'échelle mensuelle et 16% pour l'échelle annuelle. On conclut, donc, que la précision est inversement proportionnelle à l'échelle.

Notons aussi que si le critère de Nash donne une appréciation des valeurs simulées pour chaque donnée, l'erreur sur le bilan ne permet qu'une estimation globale des flux, et donc incompatible avec la prévision des concentrations de MES en temps réel. Tandis que le coefficient de corrélation donne uniquement une appréciation sur le degré de relation entre les variables simulées et observées. De ce fait, les modèles de simulation de MES doivent être validés en tenant compte des critères de Nash et de l'erreur.

La mauvaise qualité des résultats, obtenus par le modèle flou à apprentissage annuel, peut être expliquée par le fait que lors de l'apprentissage annuel certains détails de la réalité, très complexe, seront dissimulés par l'assemblage des données de l'année toute entière, entre autres, l'effet saisonnier. En effet, un débit liquide faible en période humide peut engendrer un débit solide beaucoup plus important que celui engendré par un débit liquide fort en période sèche.

Cependant, le modèle flou à apprentissage mensuel permet d'atténuer les effets saisonniers, contrairement au modèle flou à apprentissage annuel où certains détails de la réalité, très complexe, seront dissimulés par l'assemblage des données de l'année toute entière. La qualité supérieure des résultats obtenus à différentes échelles, en période de validation comme en période de calage, en utilisant ce nouveau concept donne un avantage supplémentaire aux modèles neuro-flous.

## Références bibliographiques

Achite M. (2007). Problématique de l'érosion et du transport solide en Algérie du Nord: Bassin versant de l'Oued Mina, thèse de Doctorat Es Science, Université des sciences et de la technologie d'Oran M.B., Algérie.

Benkhalel A. ET B. Remini (2003). Analyse de la relation de puissance : débit solide-débit liquide à l'échelle du bassin versant de l'Oued Wahrân. Rev. Sci. Eau, 16, 333-356.

Coulibaly, P., A. Francois & B. Bernard (1999). Prévision Hydrologique par Réseaux de Neurones Artificiels – état de l'art. Can. J. Civ. Eng. 26 PP 293-304

Dechemi N., Benkaci T. et A. Issolah, (2003). Modélisation des débits mensuels par les modèles conceptuels et les systèmes neuro-flous. Rev. Sci. Eau, 16, 407-424.

Dreyfus, G. (2004). Réseaux de neurones, Méthodologie et Application EYROLLES, 2004 pp 01-65 Fiesler, E. 1994.

Gafrej R. (1993). Modélisation conceptuelle du transfert des matières en suspension, effet d'échelles spatio-temporelles. Thèse de Doctorat, Université Paris 6, CEMAGREF.

Halgamuge K. S. ET M. Glistler (1994). Neural networks in designing fuzzy systems for real world applications. Fuzzy Sets and Systems, 65(1):1{12, 1994.

Horikawa, S. I., T. Furuhashi & Y. Uchikawa(1992). On fuzzy modelling using fuzzy neural networks with the back-propagation algorithm. IEEE Trans. On Neural networks, 3(5):801{805, 1992.

Jang J. (1993). ANFIS Adaptive-network-based fuzzy Inference Systems. IEEE SMC,23,665-685

Kassoul, M., A. Abdelgader ET M. Belorgey (1997). Caractérisation de la sédimentation des barrages en Algérie." Revue des sciences de l'eau 10 (3): 339-358.

Lefkir A., T. Benkaci & N. Dechemi (2006). Quantification du transport solide par la technique floue, application au barrage de Beni Amrane. Revue des Sciences de l'Eau 19(3) (2006) 247-257

R. Maachou, A. Lefkir, A. Khouider & A. Bermad (2015) Modeling of activated sludge process using artificial neuro-fuzzy-inference system (ANFIS), Desalination and Water Treatment, 57:45, 21182-21188, DOI: 10.1080/19443994.2015.1111596

Matthieu, G. (2003). Entraînement de Réseaux de Neurones Récurent à Pulses Appliqués à la Modélisation d'un Tissu Neuronal Biologique. thèse Maîtrise en Science Appliqué Génie Electrique, ECOLE POLYTECHNIQUE DE MONTREAL 2003 pp 14-20

Megnounif, A., A. Terfous ET A. BouananI. (2003). Production et transport des matières solides en suspension dans le bassin versant de la Haute-Tafna (nord-Ouest Algérien). Revue Sciences de l'eau 16(3): 369-380.

Menage, X ET Hartani ,R. (1993). Synthèse des méthodes d'association des techniques neuronales et des techniques floues. Technical report, LAFORIA Institut Blaise Pascal, Paris, 1993.

Paschen, H., D. Gomer, ET AL. (1998). Management of watersheds with soils on marls in the Atlas Mountains of Algeria - A proposal for a non-conventional watershed development scheme. *Advances in GeoEcologie* 31: 1099-1106.

Picouet C., Hingray B. ET J.C., Olivry (2001). Empirical and conceptual modelling of the suspended sediment dynamics in a large tropical African river: the Upper Niger river basin. *J. Hydrol*, 250, 19-39.

Terfous, A., A. Megnouif & A. Bouanani (2001). Étude du transport solide en suspension dans l'Oued Mouilah (Nord Ouest Algérien). *Revue des sciences de l'eau* 14(2): 173- 185.