

Modélisation de L'affouillement de Pont par Réseaux de Neurones Artificiels basé sur l'ACP.

Z.Nemili*¹, M. Kalla¹

¹ Laboratoire de recherche Risques Naturelles et Aménagement du territoire « LRNAT »
Université de Batna2 (Algérie).

*Corresponding author: mmez_nemili@yahoo.com

ARTICLE INFO

Article History :

Received : 22/07/2018

Accepted : 04/05/2019

Key Words:

Scouring; Bridge;
Metamodel; Neuroemulation;
PCA.

Mots clés :

Affouillement; Pont; Méta-
modèle; Neuro-émulation;
ACP.

ABSTRACT/RESUME

Abstract: The present study aims at modeling the scour depth around circular bridge piers in Algeria (semi-arid zones) by Artificial Neural Networks (neuroemulation). In the pretreatment phase, the reduction of the dimensionality of the inputs to the neuronal model is performed by the classical linear method: Principal Component Analysis (PCA). The results obtained for this type of data showed that PCA provides very powerful models.

Résumé : La présente étude a pour objet la modélisation de la profondeur d'affouillement autour des piles de pont circulaires en Algérie (Zones semi-arides) par Réseaux de Neurone Artificiels (neuro-émulation). A la phase de prétraitement, la réduction de la dimensionnalité des entrées au modèle neuronal est effectuée par la méthode classique linéaire : l'analyse en composantes principales (ACP). Les résultats obtenus pour ce type de données ont montré que l'ACP fournit des modèles très performants.

I. Introduction

L'affouillement autour des piles de pont est considéré comme l'un des domaines les plus importants des recherches hydrauliques, il peut mettre en danger toute la structure après une longue ou courte durée en fonction de l'ampleur de ses processus. Son effet néfaste peut entraîner des coûts d'entretien élevés ou même un effondrement du pont causant des perturbations du trafic et peut-être des pertes humaines [5]. De nombreux travaux ont démontré que l'affouillement est la cause principale de la rupture des ouvrages de franchissement à travers le monde [8, 18]. Deng et Cai [3] ont donné un examen complet de travaux récents où différentes techniques et instruments développés pour la surveillance et le suivi des ponts ont été représentés. La détermination de l'affouillement est effectuée par les formules empiriques, les modèles numériques et l'expérimentation, Olsen and Kjellesvig [16] ont modélisé numériquement l'écoulement en trois dimensions autour d'une pile circulaire placée verticalement dans un canal. Le modèle numérique résout les équations de Navier-Stokes avec le modèle de turbulence k-z. Une simulation numérique de l'évolution de la

profondeur d'affouillement autour des piles de pont a été étudiée par Nasr-Allah et al. [15].

Parmi les modèles numériques appliqués à ce problème, Le système de modélisation hydrodynamique unidimensionnelle HEC RAS qui a été étendu afin de faciliter les analyses d'écoulement non permanent [10, 9]. Il est utilisé pour évaluer la profondeur d'affouillement par [14] et [12], Peters, Schmitz et al. (2006) [17], ont utilisé le HEC RAS pour modéliser les crues et générer une base de données pour former les réseaux de neurones artificiels ou la capacité du modèle formé est démontré.

Afin de simplifier les modèles de calcul obtenus par expérimentation, beaucoup d'auteurs ont choisi l'application des Réseaux Artificiels de Neurones (RAN) dans le domaine des écoulements à surface libre ainsi que le transport solide, [11, 7, 2], emploient un RAN basé sur les données de laboratoire pour prédire l'affouillement local autour des piles de pont.

Le HEC RAS a été utilisé pour modéliser les inondations dans le tronçon inférieur de la rivière Freiburger Mulde et ses affluents. En outre, ce modèle a été utilisé pour générer une base de données pour former des réseaux de neurones,

l'étude a montré la fiabilité de cette méthodologie [17].

La neuro-émulation est devenue une sous-discipline reconnue et établie dans de nombreux domaines d'étude et met en évidence un certain nombre d'orientations stratégiques de la recherche en rapport avec le développement du potentiel identifié des applications des neuro-émulateurs à la modélisation des ressources en eau [1].

Dans la présente étude nous allons générer une base de données pour la détermination de l'affouillement par le modèle HEC RAS, la base de données ainsi générée sera introduite par la suite dans un modèle neuronal. Les entrées sont prétraitées par l'analyse en composantes principales (ACP).

II. Matériel et methodes

II.1. Description du programme HEC RAS

Le programme a été élaboré par le ministère américain de la Défense (corps des ingénieurs de l'armée des États-Unis) dans le but de gérer les rivières, les ports et autres travaux publics relevant de leur compétence, il a été largement diffusé de par le monde depuis sa publication en 1995. Développé par l'*Hydrologic Engineering Center (HEC)* en Californie, ce système permet aux ingénieurs en hydraulique d'analyser les débits dans les lits des rivières, de déterminer les zones inondables et d'estimer la profondeur d'affouillement autour des piles de pont. Il intègre de nombreux moyens de saisie de données, de composants d'analyse hydraulique, de stockage de données, d'édition de rapports sous forme de tables et de graphiques.

II.1.1. Modélisation de l'affouillement des pont par HEC RAS

Cette étude examine la profondeur d'affouillement autour des piles de pont à l'aide du programme HEC-RAS [Version 4.1.0, (2010)]. Une base de données a été développée, des résultats plus réalistes sont obtenus par le modèle HEC-RAS car il prend en compte des facteurs plus connexes comme l'angle d'attaque, les conditions de lit, la forme des piles, les débits, la profondeur d'écoulement et le nombre de Froude (fig.1). Toutes les données d'entrée utilisées pour les tests ont été tirées de l'étude des cas de ponts existants en zones semi-arides en Algérie.

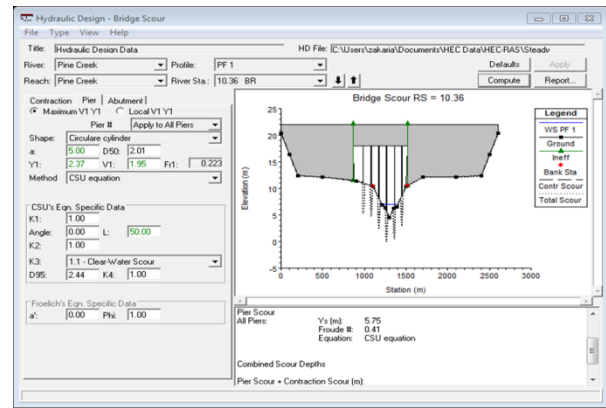


Figure 1. Données hydrauliques pour l'affouillement autour de la pile.

II.2. Réseaux de Neurones Artificiels

Les Réseaux de Neurones Artificiels sont un moyen de modéliser le mécanisme d'apprentissage et de traitement de l'information qui se produit dans le cerveau humain. La plus part des Réseaux de Neurones sont structurés en couches MLP (Fig.2).

Un Réseau de Neurones s'opère en deux phases consécutives: une phase de conception (Apprentissage et Test) et une phase d'utilisation.

- L'apprentissage consiste à modifier le poids des connections entre les neurones.
- Le test consiste à valider le réseau par l'utilisation d'un échantillon de test.
- L'utilisation :- un vecteur est présenté au réseau ;
 - Les vecteurs calculent leurs sorties ;
 - Les sorties sont propagées et on itère jusqu'à la convergence.

Le plus souvent on considère le coefficient de détermination R^2 , l'Erreur Quadratique Minimale Moyenne MSE ou l' $RMSE$.

Dans la présente étude les fonctions d'activation (les entrées) sont deux composantes présentant le résultat du traitement par composantes principales (ACP), les sorties sont les hauteurs d'affouillement.




Figure 2. Architecture d'un réseau neuronal.

II.3. Analyse en Composantes Principales

C'est une méthode statistique qui permet d'explorer des données dites multivariées, chaque variable pourrait être considérée comme une dimension différente. L'analyse en composantes principales est utilisée pour extraire et visualiser les informations importantes contenues dans une table de données multivariées. L'ACP synthétise cette information en seulement quelques nouvelles variables appelées **composantes principales**. Ces nouvelles variables correspondent à une combinaison linéaire des variables originels. Le nombre de composantes principales est inférieur ou égal au nombre de variables d'origine. En d'autres termes, l'ACP réduit les dimensions d'une donnée multivariée à deux ou trois composantes principales, qui peuvent être visualisées graphiquement, en perdant le moins possible d'information.

Une ACP s'effectue sur un tableau de (N) individus décrits par (P) variables: x_1, x_2, \dots, x_p intercorrélées et crée à partir d'elles **p** composantes principales indépendantes C_k :

$$C_k = \sum_{j=1}^p u_{jk} X_j$$

Où u_{jk} sont les vecteurs propres orthonormés de la matrice de corrélation R associés aux valeurs propres λ_k .

Dans ce travail, les entrées de l'analyse en composantes principales (ACP) sont quatre mesures : Fr, Re, Y/D et U/Uc, paramètres adimensionnels, elles sont réduites sur deux composantes (comp1, comp2) qui feront

Perdre le moins d'information possible.

III. Résultats et discussion

Nous disposons de 104 mesures (Tableau 1) celles du rapport profondeur de l'affouillement diamètre de la pile (des/D) ainsi que quatre autres paramètres retenus pour l'analyse soient : rapport de la vitesse moyenne vitesse critique (U/Uc), Reynolds (Re), rapport hauteur d'eau diamètre de la pile (Y/D) et Froude (Fr).

La matrice de corrélation (Fig.3) des quatre variables retenues montre une forte corrélation significative entre les vitesses (u/Uc) et Reynolds (Re) aussi une relation significative entre Reynolds (Re), Froude (Fr) et le rapport (Y/D) deux à deux.

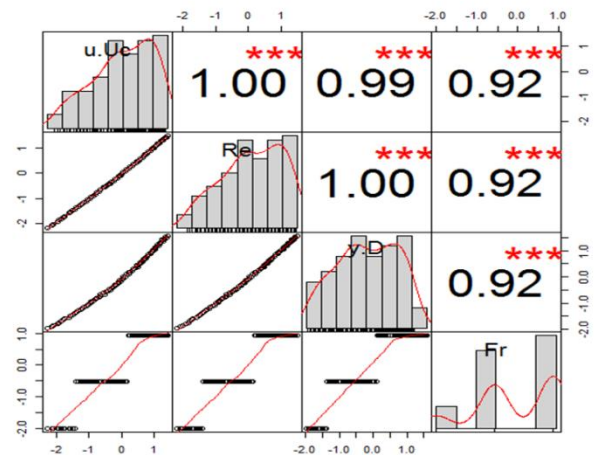


Figure 3. Matrice de corrélation.

La figure.4, présente le pourcentage d'information (inertie) présenté par chaque axe (97% sur le 1^{er} axe et 2.9 % sur le 2^{ème} axe), cela signifie que si on résume les quatre variables par une dimension, on récupère 97% de l'information contenue dans tout le tableau.

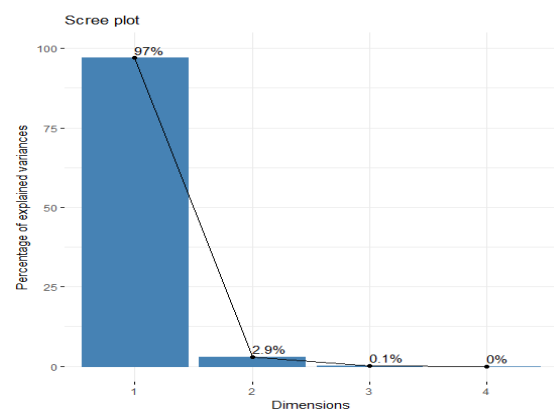


Figure 4. Scree plot.

Tableau 1. Statistiques Descriptives.

Paramètres	Unité	N	Moy.	Min	Max	Ec.Ty	Ec.Ty(Moy)	CV
Des/D	m/m	104	6.79	3.75	8.5	0.847	0.985	0.125
Fr	-	104	0.843	0.45	0.49	0.0068	0.0061	0.008
Re	-	104	1914.61	1510	2190	185.40	172.24	0.096
U/Uc	-	104	0.2309	0.1924	0.2551	0.0169	0.0141	0.073
Y/D	-	104	7.753	6.85	8.48	0.48	0.393	0.062

La première composante principale oppose le rapport des vitesses ainsi que le Reynolds, et le rapport: hauteur d'eau, diamètre de la pile (Y/D) (Fig.5). Cet axe décrit les caractéristiques hydrauliques d'écoulement et confirme bien la relation directe entre la profondeur d'affouillement et les caractéristiques hydrauliques de l'écoulement.

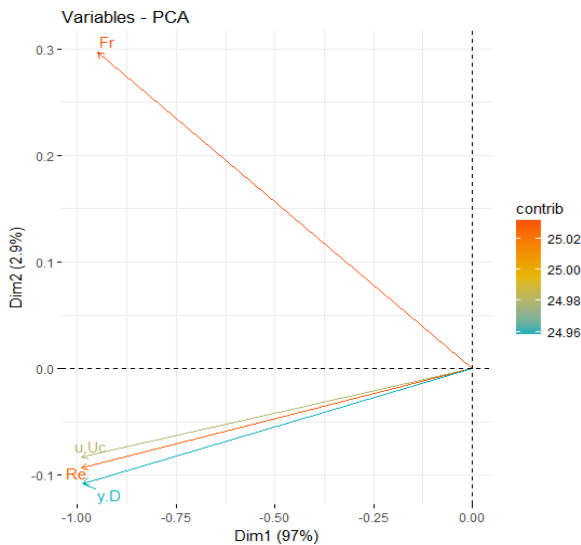


Figure 5. Représentation des variables sur les axes principaux.

III.1. Modèle neuronal

Le package neuralnet (Fritsch and Guenther 2016) est utilisé pour construire le modèle neuronal. Les 2/3 des données sont retenues pour l'apprentissage, le 1/3 restant pour la phase de test. Pour les deux nombres de composantes retenues variables, on construit un modèle neuronal pour chacune des méthodes de réduction constitué d'une couche cachée comportant trois neurones avec une fonction d'activation par défaut qui est la fonction

logistique et une fonction linéaire pour la couche de sortie (Fig.7).




Figure 7. Modèle Neuronal 2 composantes ACP.

Les résultats de simulation en fonction du nombre de composantes retenues montrent l'efficacité de l'ACP comme méthode de réduction de dimension des entrées au modèle neuronal.

En phase d'apprentissage et selon le nombre de composantes retenues, l'erreur qui correspond à la Somme des Erreurs Quadratiques « SSE » diminue pour atteindre 0.05469 pour un nombre de composantes égal à deux,

En phase de Test, le coefficient de détermination pour deux composantes est très satisfaisant concernant l'ACP, où il atteint 0.0.953 (Fig.8).

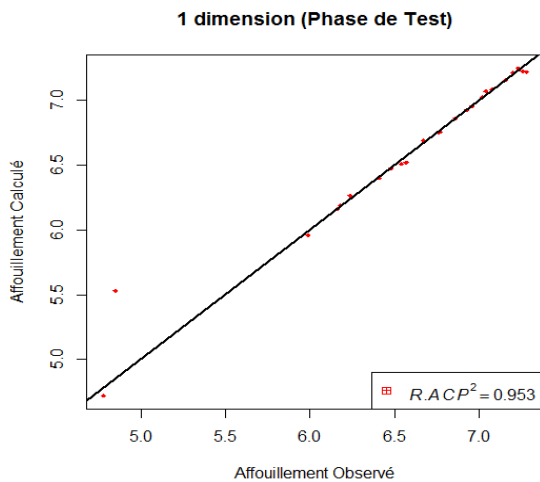


Figure 8. Performance des modèles en phase de test (2 Composantes)

VI. Conclusion

La présente étude avait pour objectif, l'évaluation du niveau d'efficacité des Réseaux de Neurones Artificiels pour la modélisation de la profondeur d'affouillement autour des piles circulaires de ponts et d'analyser la méthode classique de prétraitement ACP pour la réduction de la dimensionnalité des données. Les résultats ont démontré l'efficacité de L'ACP pour un prétraitement des entrées au modèle neuronal de l'évaluation de la profondeur d'affouillement. Ce résultat, indique que la méthode de réduction de dimension linéaire s'adapte bien aux données d'écoulement.

V. References

1. Abrahart, R.J.; Mount, N.J.; Shamseldin, A.Y. Neuroemulation: definition and key benefits for water resources research. *Hydrological Sciences Journal* 57(3) (2012) 407-23.
2. Choi, S.U. ; Cheong, S.H. Prediction of local scour around bridge piers using artificial neural networks. *The Journal of the American Water Resources Association* 42 (2) (2006) 487-94.
3. Deng, L.; Cai, C.S. Bridge Scour: Prediction, Modeling, Monitoring and countermeasures-Review. *Pract Periodical Struct Design Constr* 15(2) (2010) 125-134.
4. Dibike, Y. B. ; Solomatine, D. et al. On the encapsulation of numerical-hydraulic models in artificial neural network. *Journal of Hydraulic Research* 37(2) (1999) 147-161.

5. Elnikhely, E. A. Minimizing Scour around Bridge Pile Using Holes. *Ain Shams Engineering Journal* 8(4) (2017) 499-506.
6. Fritsch, S.; Guenther, F. Neuralnet: Training of Neural Networks. R package version 1.33 (2016).
7. Jeng, D. S.; Bateni, S.M.; Lockett, E. Neural Network Assessment for Scour Depth around Bridge Piers. The University of Sydney (2005).
8. Johnson, P.A. ; Dock, D.A. Probabilistic Bridge Scour Estimates. *J HydraulEng ASCE* 124(7) (1998) 750-754.
9. Johnson Peggy, A. ; Gleason Gary, L.; et al. Rapid Assessment of Channel Stability in Vicinity of Road Crossing. *Journal of Hydraulic Engineering* 125(6) (1999).
10. Hicks, F. E.; Peacock, K. Suitability of Hec-Ras for Flood Forecasting. *Canadian Water Resources Journal / Revue canadienne des ressourceshydriques* 30(2) (2005)159-174.
11. Kambekar, A.R.; Deo, M.C. Estimation of Group Pile Scour Using Neural Networks. *Journal of Applied Ocean Research*. (2003).
12. Kumar, D.; Hira, Y.; Sushil, H. Estimation of Scour Depth around Bridge Piers by Using Hec-Ras (2011).
13. Liong, S. Y.; Chan, W.T. Runoff volume estimates with neural networks. third international conference on the application of artificial intelligence to civil and structural engineering. Edinburgh, UK (1993) 67-70.
14. Moussa, A. M. A. Evaluation of local scour around bridge piers for various geometrical shapes using mathematical models. *Ain Shams Engineering Journal* (2017).
15. Nasr-Allah, T.; Hemdan, Y.; Abdallah, M. M.; Mohamed, G.; ShawkyAwad, A. Experimental and Numerical Simulation of Scour at Bridge Abutment Provided with Different Arrangements of Collars. *Alexandria Engineering Journal* 55(2) (2016) 1455-1463.
16. Olsen, N. R. B.; Kjellesvig, H.M. Three-dimensional numerical flow modeling for estimation of maximum local scour depth. *Journal of Hydraulic Research* 36(4) (1998) 579-590.
17. Peters, R.; Schmitz, G.; et al. Flood routing modelling with Artificial Neural Networks. *Advances in Geosciences* 9 (2006).
18. Richardson, E. V.; Davis, S.R. Evaluating scour at bridges. *Hydraulic Engineering Circular Federal Highway Administration, Washington, D.C.* 18 (2001).
19. Fritsch, S.; Guenther, F. Neuralnet: Training of Neural Networks. R package version 1.33 (2006).
20. Peters, R.; Schmitz, G.; et al. Flood routing modelling with Artificial Neural Networks. *Advances in Geosciences* 9(2006)131-136.

Please cite this Article as:

Nemili Z., Kalla M., *Modélisation de L'affouillement de Pont par Réseaux de Neurones Artificiels basé sur l'ACP*, **Algerian J. Env. Sc. Technology**, 5:3 (2019) 1036-1040