

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

"الجمهورية الجزائرية الديمقراطية الشعبية"

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

وزارة التعليم العالي والبحث العلمي

BADJI MOKHTAR-ANNABA UNIVERSITY  
UNIVERSITE BADJI MOKHTAR-ANNABA



جامعة باجي مختار - عنابة

Faculté de Technologie

Année : 2023-2024

Département d'Hydraulique

## THESE

Présentée En vue de l'obtention du diplôme de Doctorat en Hydraulique

***Contribution à la Modélisation des débits de fuite d'eau à travers les Barrages Réservoirs par le biais de l'Intelligence Artificielle : Cas des Barrages Algériens***

Option Hydraulique

Par

***Mr. Bouchehed Ala***

Devant le jury

|                |   |      |                 |  |
|----------------|---|------|-----------------|--|
| Président      | : | MCA. | BOUSLAH Soraya  | UNIV. Badji Mokhtar, Annaba                |
| Rapporteur     | : | Pr.  | HEDDAM Salim    | UNIV. 20 Août1955 Skikda                   |
| Co-Rapporteur: | : | Pr.  | DJEMILI Lakhdar | UNIV. Badji Mokhtar, Annaba                |
| Examineur      | : | Pr.  | HOUICHI Larbi   | UNIV. Batna 2                              |
| Examineur      | : | Pr.  | ZEGHADNIA Lotfi | UNIV. Mohamed Cherif Messaâdia, Souk-Ahras |
| Examineur      | : | MCA. | BOUGUERRA Hamza | UNIV. Badji Mokhtar, Annaba                |

# *Dédicaces*

*À l'aube de l'achèvement de ce travail de recherche, je tiens à exprimer ma profonde gratitude envers ceux qui ont été les piliers de mon parcours académique et personnel. Leur soutien inébranlable a été la pierre angulaire de mes réussites et le moteur qui a propulsé ma quête de connaissance.*

*C'est Avec fierté et respect que je dédie ce modeste travail :*

*À mon père, Qui a déployé d'innombrables efforts jour et nuit pour mon éducation et mon bien-être. Ce travail témoigne des sacrifices considérables que tu as consentis pour mon instruction et ma formation.*

*À ma mère bien-aimée, Tu incarnes l'exemple suprême de dévouement, car tu n'as jamais cessé de m'encourager et de prier pour moi. Puissent les bénédictions de Dieu, le Tout-Puissant, te préserver et t'accorder santé, longévité et bonheur.*

*À mes frères et sœurs, compagnons de chaque étape de ma vie. Vos encouragements ont été la source de mes forces.*

*À mes neveux et nièces, dont l'innocence et la joie de vivre ont éclairé mes journées les plus sombres.*

*À mes amis, compagnons de discussions stimulantes et de moments de détente. Votre soutien moral a été un élément essentiel pour mon équilibre personnel et professionnel.*

*Ensemble, vous avez constitué le socle solide sur lequel repose cette réalisation. Mes mots de remerciement semblent modestes en comparaison de la profondeur de ma gratitude. Que cette dédicace soit le témoignage humble de l'amour et de la reconnaissance que je ressens envers chacun d'entre vous.*

# *Remerciements*

*Tout d'abord, je tiens à exprimer ma gratitude envers le Tout-Puissant, qui a éclairé ma voie et m'a pourvu de courage, de volonté et de patience afin de mener à bien cette tâche.*

*Je tiens à exprimer mes sincères remerciements aux personnes qui ont apporté une contribution significative à la réalisation de cette thèse de doctorat.*

*Je tiens à exprimer ma profonde gratitude envers mon directeur de thèse, le Professeur **Heddam Salim**. Ce moment est l'occasion pour moi de renouveler ma plus grande estime et ma reconnaissance à votre égard. Je souhaite exprimer mes plus sincères remerciements pour votre engagement exceptionnel et votre guidance éclairée tout au long de la réalisation de cette thèse. Je suis reconnaissant de l'opportunité qui m'a été offerte de bénéficier de votre direction attentive. Monsieur, sans votre présence, le travail n'aurait pas été aussi réussi. Il m'est difficile d'exprimer toute ma gratitude, alors je vous dis simplement merci.*

*Mes vifs remerciements vont également à mon Co-encadrant, **Pr. Djemili Lakhdar**, dont la collaboration précieuse a grandement contribué à l'enrichissement de mes travaux. Sa vision et ses conseils ont été des atouts inestimables.*

*Je n'oublie pas de témoigner ma reconnaissance envers Monsieur **Laaouchria Fares**, qui a fourni beaucoup d'efforts afin de m'aider.*

*Je tiens à exprimer ma profonde gratitude envers Madame **Bousslah Soraya**, enseignante à l'université Badji Mokhtar Annaba, qui a généreusement accepté de présider le jury. Sa participation mérite toutes les reconnaissances.*

*Je souhaite exprimer ma reconnaissance envers Monsieur **Houichi Larbi**, Professeur à l'université Hadj Lakhdar, Batna, Monsieur **Zeghadnia Lotfi**, Professeur à l'université Mohamed Cherif Messaâdia, Souk-Abras, ainsi que Monsieur **Bougerra Hamza**, enseignant à l'université Badji Mokhtar Annaba, pour avoir accepté de participer à mon jury de thèse. Merci pour leur contribution précieuse.*

*Je tiens à exprimer ma gratitude envers l'ensemble de mes enseignants et collègues tout au long de mon parcours universitaire. De plus, je souhaite remercier chaleureusement toutes les personnes ayant contribué de près ou de loin à la réalisation de ce travail.*

# Table des matières

|  |           |
|--|-----------|
| <b>Résumé :</b> .....  | XI        |
| <b>ملخص:</b> .....   | XI        |
| <b>Abstract:</b> .....   | XII       |
| <b>Introduction Générale</b> .....                               | <b>1</b>  |
| <b>Chapitre I : Généralités sur les Barrages en Terres</b> ..... | <b>4</b>  |
| <b>I.1. Introduction</b> .....                                   | <b>5</b>  |
| <b>I.2. Historiques</b> .....                                    | <b>6</b>  |
| <b>I.3. Types de Barrages en Remblai</b> .....                   | <b>8</b>  |
| I.3.1. Barrage Homogène.....                                     | 9         |
| I.3.2. Barrage Zoné .....  | 9         |
| I.3.3. Barrages en enrochement .....                             | 9         |
| <b>I.4. Critères de Conception</b> .....                         | <b>11</b> |
| I.4.1. Géologie .....  | 11        |
| I.4.2. Morphologie et Topographie.....                           | 12        |
| I.4.3. Hydrologie.....   | 12        |
| <b>I.5. Matériaux de Construction</b> .....                      | <b>12</b> |
| <b>I.6. Défaillance Des Barrages en Remblai</b> .....            | <b>15</b> |
| I.6.1. Défaillances Hydrauliques .....                           | 15        |
| I.6.2. Échecs D'infiltration .....                               | 16        |
| I.6.3. Défaillances Structurelles.....                           | 16        |
| <b>I.7. Stabilités.</b> .....                                    | <b>16</b> |
| <b>I.8. Les Fuites</b> .....                                     | <b>18</b> |
| I.8.1. Infiltration à Travers la Digue .....                     | 18        |
| I.8.2. Infiltration à Travers la Fondation .....                 | 19        |
| I.8.3. Drains .....  | 20        |
| I.8.4. Les Caractéristiques Des Filtres.....                     | 21        |
| I.8.5. Conditions De Décharge. ....                              | 21        |
| I.8.6. Emplacement Et Géométrie. ....                            | 21        |
| <b>I.9. Les piézomètres</b> .....                                | <b>22</b> |
| Piézomètres pour les pressions d'infiltration.....               | 23        |

|   |           |
|---|-----------|
| I.9.1. Fondation.....   | 23        |
| I.9.2. Remblai. ....  | 24        |
| I.9.3. Drains. ....   | 25        |
| I.9.4. Zones en aval.....   | 26        |
| <b>I.10. Conclusion .....</b>   | <b>26</b> |
| <b>Chapitre II: Présentation des Barrages Algériens et Description de la Base de Données.....</b>                                     | <b>27</b> |
| <b>II.1. Introduction .....</b>   | <b>28</b> |
| <b>II.2. Description des Barrages .....</b>   | <b>29</b> |
| II.2.1. Barrage Zit el Emba .....   | 29        |
| II.2.2. Barrage Foug el Khanga .....  | 30        |
| II.2.3. Barrage Bougous.....  | 32        |
| II.2.4. Barrage Hammam Debagh.....  | 33        |
| II.2.5. Barrage Cheurfas II.....  | 34        |
| <b>II.3. Présentation et Description de la Base de Données Utilisée .....</b>   | <b>35</b> |
| <b>II.4. Conclusion.....</b>  | <b>37</b> |
| <b>Chapitre III: Description des Modèles à Base d'Intelligences Artificielles ..</b>  | <b>38</b> |
| <b>III.1. Introduction .....</b>  | <b>39</b> |
| <b>III.2. Réseaux De Neurones Artificiels .....</b>   | <b>39</b> |
| <b>III.3. Les Perceptrons Multicouches (MLPNN).....</b>   | <b>40</b> |
| III.3.1. L'Algorithme de Rétropropagation du Gradient (BP) .....  | 42        |
| <b>III.4. Les Réseaux de Neurones à Fonction de Base Radiales (RBFNN) .....</b>   | <b>42</b> |
| <b>III.5. Réseaux de Neurones de Régression Généralisée (GRNN).....</b>   | <b>45</b> |
| <b>III.6. Système d'Inférence Flou à base de Réseaux de Neurones Adaptatifs (ANFIS) : ..</b>  | <b>47</b> |
| III.6.1. Optimisation des Règles Floues du Modèle ANFIS .....   | 49        |
| <b>III.7. Machine à Vecteurs de Support des Moindres Carrées (LSSVM) .....</b>  | <b>50</b> |
| <b>III.8. Régression Multivariée par Spline Adaptative (MARS) .....</b>   | <b>52</b> |
| <b>III.9. M5 Model Tree (M5Tree).....</b>   | <b>53</b> |
| <b>III.10. Conclusion.....</b>  | <b>55</b> |
| <b>Chapitre IV : Modélisation des Débits de Fuite par les Techniques à Base l'Intelligence Artificielle &amp; Etat de l'Art .....</b> | <b>56</b> |
| <b>IV.1. Introduction .....</b>   | <b>57</b> |
| <b>IV.2. Modélisation du Débit de Fuite par les Modèles ANN .....</b>   | <b>58</b> |

|  |            |
|--|------------|
| IV.2.1. Modélisation du Débit de Fuite par les modèles MLPNN : .....   | 59         |
| IV.2.2. Modélisation Du Débit De Fuite par les modèles RBFNN : .....   | 61         |
| <b>IV.3. Modélisation du Débit de Fuite par les modèles MLR et MNL</b> .....   | <b>62</b>  |
| <b>IV.4. Modélisation du Débit de Fuite par les modèles à base de noyau.</b> .....                                     | <b>62</b>  |
| <b>IV.5. Modélisation du Débit de Fuite par les modèles MARS</b> .....   | <b>64</b>  |
| <b>IV.6. Modèle D'arbre de Décision Pour La Modélisation du Débit de Fuite :</b> .....                                 | <b>65</b>  |
| IV.6.1. M5Tree Pour La Modélisation Du Débit Des Fuites .....  | 65         |
| IV.6.2. Forêt Aléatoire (RF) Pour La Modélisation Du Débit De Fuites .....   | 66         |
| <b>IV.7. Le modèle Neuro-Floue pour la modélisation du Débit De Fuites</b> .....                                       | <b>67</b>  |
| <b>IV.8. Modèles Hybrides pour la modélisation du Débit de fuite.</b> .....  | <b>68</b>  |
| <b>IV.9. Conclusion.</b> .....   | <b>69</b>  |
| <b>Chapitre V : Modélisation des Débits de Fuite par les Modèles à Base des Réseaux de Neurones Artificiels.</b> ..... | <b>70</b>  |
| <b>V.1. Introduction.</b> .....  | <b>71</b>  |
| <b>V.2. Critères de validation des performances des modèles</b> .....  | <b>71</b>  |
| <b>V.3. La Mise En Œuvre Des Modèles De Réseaux Neurone</b> .....  | <b>72</b>  |
| <b>V.4. Résultats Obtenus par les modèles ANN: Barrage Bougous</b> .....   | <b>73</b>  |
| <b>V.5. Résultats Obtenus par les modèles ANN: Barrage Cheurfas</b> .....  | <b>80</b>  |
| <b>V.6. Résultats Obtenus par les modèles ANN: Barrage Zit Emba</b> .....  | <b>88</b>  |
| <b>V.7. Résultats Obtenus par les modèles ANN: Barrage Foum el Khanga</b> .....  | <b>95</b>  |
| <b>V.8. Résultats Obtenus par les modèles ANN: Barrage Hammam Debagh</b> .....   | <b>103</b> |
| <b>V.9. Conclusion</b> .....   | <b>105</b> |
| <b>Chapitre VI: Modélisation des Débits de Fuite par Les Modèles Neuroflous</b> .....                                  | <b>107</b> |
| <b>VI.1. Introduction</b> .....  | <b>108</b> |
| <b>VI.2. Mise En Œuvre du modèle ANFIS sous Matlab</b> .....   | <b>108</b> |
| <b>VI.3. Résultats Obtenus par les modèles Neuroflous: Barrage Bougous</b> .....                                       | <b>108</b> |
| <b>V.4. Résultats Obtenus par les modèles Neuroflous: Barrage Cheurfas</b> .....                                       | <b>114</b> |
| <b>VI.5. Résultats Obtenus par les modèles Neuroflous: Barrage De Zit Emba</b> .....                                   | <b>119</b> |
| <b>VI.6. Résultats Obtenus par les modèles Neuroflous : Barrage Foum el Khanga</b> .....                               | <b>126</b> |
| <b>VI.7. Résultats Obtenus par les modèles Neuroflous: Barrage Hammam Debagh</b> .....                                 | <b>133</b> |
| <b>VI.8. Conclusion</b> .....  | <b>135</b> |

|  |            |
|--|------------|
| <b>Chapitre VII : Modélisation des Débits de Fuite par Les Modèles</b>                     |            |
| <b>Ensemblelistes.....</b>   | <b>137</b> |
| <b>VII.1. Introduction.....</b>  | <b>138</b> |
| <b>VII.2. Mise En Œuvre Des Modèles Ensembleliste Sous Matlab .....</b>                    | <b>138</b> |
| <b>VII.3. Résultats Obtenus par les modèles Ensembleliste : Barrage Bougous .....</b>      | <b>139</b> |
| <b>VII.4. Résultats Obtenus par les Modèles Ensemblelistes : Barrage Cheurfas.....</b>     | <b>147</b> |
| <b>VII.5. Résultats Obtenus par les Modèles Ensemblelistes : Barrage Zit Emba .....</b>    | <b>156</b> |
| <b>VII.6. Résultats Obtenus par les Modèles Ensemblelistes: Barrage Foum El Khanga....</b> | <b>164</b> |
| <b>VI.7. Résultats Obtenus par les modèles Neuroflous: Barrage Hammam Debagh.....</b>      | <b>173</b> |
| <b>VII.8. Conclusion .....</b>   | <b>176</b> |
| <b>Conclusion Générale .....</b>   | <b>177</b> |
| <b>Références Bibliographiques .....</b>   | <b>179</b> |

# Liste des Figures

|   |    |
|---|----|
| <b>Figure I. 1.</b> Section transversale du barrage Sadd-El-Kafara. (Tanchev, 2014) .....   | 6  |
| <b>Figure I. 2.</b> Section transversale de différents types des barrages en remblais. (Kutzner, 1997)<br>.....   | 10 |
| <b>Figure I. 3.</b> Diagramme de classification des sols cohésifs (Unified Soil Classification Chart, adapté de (Kutzner, 1997)). (1) Indice de plasticité, (2) limite de liquide (%) and (3) A-line. | 14 |
| <b>Figure I. 4.</b> Modes de défaillance des barrages en remblai. ....  | 15 |
| <b>Figure I. 5.</b> Stabilité du talus & Emplacement des plans de glissement critiques (Kutzner, 1997).....   | 17 |
| <b>Figure I. 6.</b> Surface phréatique dans un barrage « homogène ». (Kutzner, 1997) .....  | 19 |
| <b>Figure I. 7.</b> Barrage en enrochement avec noyau de terre vertical. Infiltration à travers le barrage et les fondations après la mise en fourrière. (Kutzner, 1997).....                         | 20 |
| <b>Figure I. 8.</b> Utilisation de drains inclinés et horizontaux pour le contrôle des infiltrations (Brown, 1993) .....  | 20 |
| <b>Figure I. 9.</b> Conception de drains inclinés et horizontaux pour un drainage optimal. (Brown, 1993).....   | 21 |
| <b>Figure I. 10.</b> Installation des piézomètres dans la fondation des barrages. (Brown, 1993) ....  | 23 |
| <b>Figure I. 11.</b> Installation des piézomètres dans couche superficielle. (Brown, 1993) .....  | 24 |
| <b>Figure I. 12.</b> Aménagement de l'installation piézométrique du barrage Baldershead (Brown, 1993).....  | 25 |
| <b>Figure I. 13.</b> Installation des piézomètres pour barrages avec infiltration et sous-infiltration (Brown, 1993) .....  | 26 |
| <b>Figure II. 1.</b> Présentation l'emplacement des cinq barrages étudiés. ....   | 28 |
| <b>Figure II. 2.</b> Situation Géographique du barrage Zit Emba (Skikda).....   | 29 |
| <b>Figure II. 3.</b> Présentation l'emplacement du barrage Fougou el Khanga ( <b>Oum El Baouaghi</b> ).31   |    |
| <b>Figure II. 4.</b> Présentation l'emplacement du barrage Bougous ( <b>Tarf</b> ). ....  | 32 |
| <b>Figure II. 5.</b> Présentation l'emplacement barrage Hammam Debagh ( <b>Guelma</b> ). ....   | 34 |
| <b>Figure II. 6.</b> Présentations l'emplacement du barrage Chaurfas ( <b>Mascara</b> ). ....   | 35 |
| <b>Figure III. 1.</b> Traitement du signal dans un neurone artificiel. ....   | 40 |
| <b>Figure III. 2.</b> Schéma détaillé d'un perceptron multicouche (MLPNN).....  | 41 |
| <b>Figure III. 3.</b> Architecture Détaillée des Réseaux de Neurones RBFNN. ....  | 43 |
| <b>Figure III.4 .</b> Schéma général du réseau de neurones GRNN (Heddami, 2017). ....   | 45 |
| <b>Figure III. 5.</b> Système d'Inférence Floue à base de Réseaux de Neurones Adaptatifs (ANFIS).<br>.....  | 48 |
| <b>Figure III. 6.</b> L'architecture détaillée du modèle LSSVM.....   | 51 |
| <b>Figure III.7 .</b> L'architecture détaillée du modèle MARS.....  | 53 |
| <b>Figure III.8.</b> L'architecture détaillée du modèle M5Tree. ....  | 54 |
| <b>Figure V. 1.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents MLPNN modèles : barrage Bougous & phase de validation .....                               | 75 |
| <b>Figure V. 2.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents RBFNN modèles : barrage Bougous & phase de validation.....                                | 76 |
| <b>Figure V. 3.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents GRNN modèles : barrage Bougous & phase de validation.....                                 | 77 |

|   |     |
|---|-----|
| <b>Figure V. 4.</b> Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Bougouss.....                               | 80  |
| <b>Figure V. 5.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles : Barrage Bougouss. ....   | 80  |
| <b>Figure V. 6.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents MLPNN modèles: barrage Cheurfas & phase de validation.....                | 82  |
| <b>Figure V. 7.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents RBFNN modèles: barrage Cheurfas & phase de validation. ....               | 85  |
| <b>Figure V. 8.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents GRNN modèles: barrage Cheurfas & phase de validation. ....                | 86  |
| <b>Figure V. 9.</b> Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Cheurfas. ....                              | 87  |
| <b>Figure V. 10.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles : Barrage Cheurfas.....   | 87  |
| <b>Figure V. 11.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents MLPNN modèles: barrage Zit Emba & phase de validation. ....              | 91  |
| <b>Figure V. 12.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents RBFNN modèles: barrage Zit Emba & phase de validation.....               | 92  |
| <b>Figure V. 13.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents GRNN modèles: barrage Zit Emba & phase de validation.....                | 93  |
| <b>Figure V. 14.</b> Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Zit Emba.....                              | 95  |
| <b>Figure V. 15.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs modèles ANN: Barrage Zit Emba. ....   | 95  |
| <b>Figure V. 16.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents MLPNN modèles: barrage Foum El Khanga & phase de validation.....         | 99  |
| <b>Figure V. 17.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents RBFNN modèles: barrage Foum El Khanga & phase de validation. ....        | 100 |
| <b>Figure V. 18.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents GRNN modèles: barrage Foum El Khanga & phase de validation. ....         | 101 |
| <b>Figure V. 19.</b> Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Foum el Khanga. ....                       | 102 |
| <b>Figure V. 20.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles: Barrage Foum el Khanga.....  | 102 |
| <b>Figure V. 21.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles ANN: barrage Hammam Debagh & phase de validation. ....           | 103 |
| <b>Figure V. 22.</b> Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Hammam Debagh. ....                        | 105 |
| <b>Figure V. 23.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles: Barrage Hammam Debagh. ....  | 105 |
| <b>Figure VI. 1.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS_SC: barrage Bougous & phase de validation. .... | 110 |
| <b>Figure VI. 2.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS_FC: barrage Bougous & phase de validation. .... | 111 |

|   |     |
|---|-----|
| <b>Figure VI. 3.</b> Comparaison entre les différents modèles Neuroflous par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Bougouss.....                               | 113 |
| <b>Figure VI. 4.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs modèles Neuroflous: Barrage Bougouss. ....  | 113 |
| <b>Figure VI. 5.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS_SC: barrage Cheurfas & phase de validation. ....        | 115 |
| <b>Figure VI. 6.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS_FC: barrage Cheurfas & phase de validation. ....        | 116 |
| <b>Figure VI. 7.</b> Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Cheurfas. ....                                     | 119 |
| <b>Figure VI. 8.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles : Barrage Cheurfas.....   | 119 |
| <b>Figure VI. 9.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS_SC : barrage Zit Emba & phase de validation.....        | 122 |
| <b>Figure VI. 10.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS_FC : barrage Zit Emba & phase de validation.....       | 123 |
| <b>Figure VI. 11.</b> Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Zit Emba. ....                                    | 125 |
| <b>Figure VI. 12.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles: Barrage Zit Emba.....   | 125 |
| <b>Figure VI. 13.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS_SC: barrage Foum el Khanga & phase de validation. .... | 127 |
| <b>Figure VI. 14.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS_FC: barrage Foum el Khanga & phase de validation. .... | 128 |
| <b>Figure VI. 15.</b> Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Foum el Khanga.....                               | 132 |
| <b>Figure VI. 16.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles: Barrage Foum el Khanga. ....  | 132 |
| <b>Figure VI. 17.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous: barrage Hammam Debagh & phase de validation. ....           | 133 |
| <b>Figure VII. 1.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles LSSVM: barrage Bougous & phase de validation.....                       | 141 |
| <b>Figure VII. 2.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles MARS: barrage Bougous & phase de validation.....                        | 142 |
| <b>Figure VII. 3.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles M5Tree: barrage Bougous & phase de validation. ....                     | 143 |
| <b>Figure VII. 4.</b> Comparaison entre les différents modèles ensemblistes par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Bougous. ....                            | 146 |
| <b>Figure VII. 5.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles : Barrage Bougous.....   | 147 |
| <b>Figure VII. 6.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles LSSVM: barrage Cheurfas & phase de validation. ....                     | 151 |

|   |     |
|---|-----|
| <b>Figure VII. 7.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles MARS: barrage Cheurfas & phase de validation. ....                | 152 |
| <b>Figure VII. 8.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles M5Tree: barrage Cheurfas & phase de validation. ....              | 153 |
| <b>Figure VII. 9.</b> Comparaison entre les différents modèles Ensemblistes par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Cheurfas. ....                     | 155 |
| <b>Figure VII. 10.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs modèles Ensemblistes: Barrage Cheurfas. ....  | 155 |
| <b>Figure VII. 11.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles LSSVM: barrage Zit Emba & phase de validation. ....              | 158 |
| <b>Figure VII. 12.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles MARS: barrage Zit Emba & phase de validation. ....               | 159 |
| <b>Figure VII. 13.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles M5Tree: barrage Zit Emba & phase de validation. ....             | 160 |
| <b>Figure VII. 14.</b> Comparaison entre les différents modèles Ensemblistes par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Zit Emba. ....                    | 163 |
| <b>Figure VII. 15.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs modèles Ensemblistes: Barrage Zit Emba. ....  | 164 |
| <b>Figure VII. 16.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles LSSVM: barrage Foum El Khanga & phase de validation. ....        | 167 |
| <b>Figure VII. 17.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles MARS: barrage Foum El Khanga & phase de validation. ....         | 168 |
| <b>Figure VII. 18.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles M5Tree: barrage Foum El Khanga & phase de validation. ....       | 169 |
| <b>Figure VII. 19.</b> Comparaison entre les différents modèles Ensemblistes par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Foum El Khanga. ....              | 172 |
| <b>Figure VII. 20.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs modèles ensemblistes: Barrage Foum El Khanga. ....  | 172 |
| <b>Figure VII. 21.</b> Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Ensemblistes : barrage Hammam Debagh & phase de validation. .... | 174 |
| <b>Figure VII. 22.</b> Comparaison entre les différents modèles Ensemblistes par les diagrammes en boîte (Boxplot) et en violon (Violinplot) : Barrage Hammam Debagh. ....              | 175 |
| <b>Figure VII. 23.</b> Le diagramme de Taylor pour la comparaison entre les meilleurs modèles ensemblistes: Barrage Foum El Khanga. ....  | 176 |

# Liste des tableaux

|  |     |
|--|-----|
| <b>Tableau I. 1.</b> Symboles de groupe et noms typiques des sols (USBR, 1984).....              | 13  |
| <b>Tableau II. 1.</b> Caractéristiques techniques du barrage Zit Emba.....                       | 30  |
| <b>Tableau II. 2.</b> Caractéristiques techniques du barrage Foum el Khanga.....                 | 31  |
| <b>Tableau II. 3.</b> Caractéristiques techniques du barrage Bougous.....                        | 33  |
| <b>Tableau II. 4.</b> Caractéristiques techniques du barrage Hammam Debagh.....                  | 33  |
| <b>Tableau II. 5.</b> Caractéristiques techniques du barrage Cheurfas.....                       | 34  |
| <b>Tableau II. 6.</b> Statistiques descriptives de la base de données utilisée.....              | 36  |
| <b>Tableau II. 7.</b> Taille de la base de données utilisée.....                                 | 37  |
| <b>Tableau IV. 1.</b> Modèles à base de réseaux MLPNN pour la modélisation du débit de fuite..   | 60  |
| <b>Tableau IV. 2.</b> Modèles à base de réseaux RBFNN pour la modélisation du débit de fuite. .  | 61  |
| <b>Tableau IV. 3.</b> Modèles MLR et MNLR pour la modélisation du débit de fuite.....            | 62  |
| <b>Tableau IV. 4.</b> Modèles à base de noyau pour la modélisation du débit de fuite.....        | 63  |
| <b>Tableau IV. 5.</b> Modèles MARS pour la modélisation du débit de fuite.....                   | 65  |
| <b>Tableau IV. 6.</b> Modèles M5Tree pour la modélisation du débit de fuite.....                 | 66  |
| <b>Tableau IV. 7.</b> Modèles de Forêt Aléatoire pour la modélisation du débit de fuite.....     | 67  |
| <b>Tableau IV. 8.</b> Modèles Neuro-Floue pour la modélisation du débit de fuite.....            | 68  |
| <b>Tableau IV. 9.</b> Modèles Hybrides pour la modélisation du débit de fuite.....               | 69  |
| <b>Tableau V. 1.</b> Structure des modèles utilisées pour le Barrage Bougous.....                | 73  |
| <b>Tableau V. 2.</b> Performances des différents modèles de MLPNN & barrage Bougous.....         | 74  |
| <b>Tableau V. 3.</b> Performances des différents modèles de RBFNN & barrage Bougous.....         | 74  |
| <b>Tableau V. 4.</b> Performances des différents modèles de GRNN & barrage Bougous.....          | 78  |
| <b>Tableau V. 5.</b> Structure des modèles utilisées dans Barrage Cheurfas.....                  | 81  |
| <b>Tableau V. 6.</b> Performances des différents modèles de MLPNN & barrage Cheurfas.....        | 81  |
| <b>Tableau V. 7.</b> Performances des différents modèles de RBFNN & barrage Cheurfas.....        | 83  |
| <b>Tableau V. 8.</b> Performances des différents modèles de GRNN & barrage Cheurfas.....         | 84  |
| <b>Tableau V. 9.</b> Structure des modèles utilisées dans Barrage Zit Emba.....                  | 88  |
| <b>Tableau V. 10.</b> Performances des différents modèles de MLPNN & barrage Zit Emba.....       | 88  |
| <b>Tableau V. 11.</b> Performances des différents modèles de RBFNN & barrage Zit Emba.....       | 94  |
| <b>Tableau V. 12.</b> Performances des différents modèles de GRNN & barrage Zit Emba.....        | 94  |
| <b>Tableau V. 13.</b> Structure des modèles utilisées dans Barrage Foum el Khanga.....           | 96  |
| <b>Tableau V. 14.</b> Performances des différents modèles de MLPNN & barrage Foum el Khanga..... | 96  |
| <b>Tableau V. 15.</b> Performances des différents modèles de RBFNN & barrage Foum el Khanga..... | 98  |
| <b>Tableau V. 16.</b> Performances des différents modèles de GRNN & barrage Foum el Khanga.....  | 98  |
| <b>Tableau V. 17.</b> Performances des différents modèles ANN & barrage Hammam Debagh....        | 103 |
| <b>Tableau VI. 1.</b> Performances des différents modèles Neuroflous & barrage Bougous.....      | 112 |
| <b>Tableau VI. 2.</b> Performances des différents modèles Neuroflous & barrage Cheurfas.....     | 117 |
| <b>Tableau VI. 3.</b> Performances des différents modèles Neuroflous & barrage Zit Emba.....     | 120 |

|  |     |
|--|-----|
| <b>Tableau VI. 4.</b> Performances des différent modèles Neuroflous & barrage Foum el Khanga.<br>.....   | 126 |
| <b>Tableau VI. 5.</b> Performances des différent modèles Neuroflous & barrage Hammam Debagh.<br>.....    | 133 |
| <b>Tableau VII. 1.</b> Performances des différent modèles Ensemblistes & barrage Bougous. ....           | 140 |
| <b>Tableau VII. 2.</b> Performances des différent modèles Ensemblistes & barrage Cheurfas. ....          | 148 |
| <b>Tableau VII. 3.</b> Performances des différents modèles Neuroflous & barrage Zit Emba. ....           | 157 |
| <b>Tableau VII. 4.</b> Performances des différents modèles Neuroflous & barrage Foum El<br>Khanga. ....  | 165 |
| <b>Tableau VII. 5.</b> Performances des différents modèles Ensemblistes & barrage Hammam<br>Debagh. .... | 173 |

**Nom et Prénom : BOUCHEHED Ala**

**Thème : Contribution à la Modélisation des débits de fuite d'eau à travers les Barrages Réservoirs par le biais de l'Intelligence Artificielle : Cas des Barrages Algériens**

### **Résumé :**

Durant les dernières années le nombre de barrages construits en Algérie a significativement augmenté. Malgré leur importance, les barrages souffrent de plusieurs problèmes, parmi lesquelles les fuites à travers les digues. Les observations expérimentales ont démontré que les fuites influent directement sur la stabilité des barrages et peuvent menacer l'ouvrage en lui-même. Dans le cadre de cette étude, deux types de variables d'entrée ont été utilisés pour développer les modèles : le niveau d'eau du réservoir (CPE) et le niveau piézométrique (PZ) mesurés à l'aide de différents piézomètres sur cinq barrages situés dans différentes régions du nord Algérien. Différentes techniques à base d'intelligence artificielle, à savoir les réseaux de neurones artificiel (ANN), Neuro-Floue (ANFIS) et les Modèles Ensemblistes. Pour estimer et modéliser les débits des fuites (Q) à l'échelle journalière. L'étude a été basée sur la construction de 12 modèles utilisant des différentes combinaisons des variables d'entrée pour Proposer une structure appropriée des modèles à développer. Les résultats obtenus dans le cadre de cette étude ont démontrés la bonne capacité et l'efficacité des modèles à base d'intelligence artificielle (ANN, ANFIS, LSSVM, MARS , M5Tree), à prédire avec une grande précision les valeurs de ces débits de fuite d'eau à travers les Barrages dans la zone d'étude en fonction des critères de validation, y compris le coefficient de corrélation (R), le coefficient de Nash (NSE), et la racine moyens carrés des erreurs (RMSE) et la moyenne de l'erreur absolue (MAE).

### **ملخص:**

عرفت السنوات الأخيرة، زياد كبيرة في عدد السدود التي تم تشييدها في الجزائر. على الرغم من أهمية البالغة للسدود، فهي مع ذلك تواجه العديد من مشاكل، من بينها مشكلة التسربات عبر هياكل السدود. أظهرت الملاحظات التجريبية أن التسربات تؤثر بشكل مباشر على استقرار السدود ويمكن أن تشكل تهديدًا للبنية الهيكل نفسه. في سياق هذه الدراسة، تم استخدام نوعين من المتغيرات الإدخال لتطوير النماذج: مستوى المياه في الخزان (CPE) ومستوى المياه في الأنابيب البيزومترية (PZ) التي تم قياسها باستخدام بيزومترات مختلفة في خمسة سدود موزعة في مواقع مختلفة في الشمال الجزائري. تم استخدام تقنيات مختلفة تعتمد على الذكاء الاصطناعي، وهي الشبكات العصبية الاصطناعية (ANN) ، والنظام العصبي-الغامض (ANFIS) ، ونماذج التشكيل الجماعي، لتقدير وتحديد تدفق التسرب (Q) على المدار اليومي. شملت الدراسة بناء 12 نموذجًا باستخدام مجموعات الإدخال مختلفة لاقتراح هيكل نموذج مناسب للتطوير. أظهرت النتائج التي تم الحصول عليها في هذه الدراسة قدرة وكفاءة عالية للنماذج المعتمدة على الذكاء الاصطناعي (ANN، ANFIS، MARS، LSSVM، M5Tree) في التنبؤ بقيم تدفق تسرب المياه عبر السدود في منطقة الدراسة بدقة عالية. تم تقييم ذلك بناءً على معايير التحقق، بما في ذلك معامل الارتباط (R) ، وكفاءة ناش-ساتكليف (NSE) ، وخطأ الجذر التربيعي المتوسط (RMSE) ، وخطأ المتوسط المطلق (MAE) .

**Abstract:**

In recent years, the number of dams constructed in Algeria has significantly increased. Despite their importance, dams face various issues, among them, the leaks through the embankments. Experimental observations have demonstrated that leaks directly influence the stability of dams and can pose a threat to the structure itself. In the context of this study, two types of input variables were utilized to develop models: the reservoir water level (**CPE**) and the piezometric level (**PZ**) measured using different piezometers at five dams located in different northern Algerian regions. Various artificial intelligence-based techniques, namely Artificial Neural Networks (**ANN**), Neuro-Fuzzy (**ANFIS**) and Ensemble Models, were employed for modeling seepage flow (**Q**) on a daily scale. The study involved constructing 12 models using different input combinations to propose an appropriate model structure for development. The results obtained in this study demonstrated the robust capacity and efficiency of artificial intelligence-based models (**ANN**, **ANFIS**, **LSSVM**, **MARS**, and **M5Tree**) to predict water seepage flow values through dams in the study area with high precision. This was assessed based on validation criteria, including the correlation coefficient (**R**), Nash-Sutcliffe efficiency (**NSE**), root mean square error (**RMSE**), and mean absolute error (**MAE**).

**Mots-clés :** Niveau piézométrique, modélisation, réseaux de neurones artificiel (**ANN**), Neuro-Floue (**ANFIS**), Les Modèles Ensemblistes, intelligence artificiel, Niveau d'eau du réservoir (**CPE**), Nord d'Algérie, débit de fuite.

الكلمات المفتاحية: المستوى البيزو متري، النمذجة، الشبكات العصبية (**ANN**)، الاصطناعية، نظام الاستدلال العصبي الضبابي (**ANFIS**)، ونماذج التجميع، الذكاء الاصطناعي، مستوى الماء في الخزان، الشمال الجزائري، تدفق تسرب.

**Key words:** Piezometric level (**PZ**), Modeling, artificial neural network (**ANN**), Neuro-Fuzzy (**ANFIS**), Ensemble Models, Artificial intelligence, Reservoir water level (**CPE**), north Algeria, Seepage flow.

*Année Universitaire 2023/2024*

## Introduction Générale

L'eau, en tant qu'un des éléments fondamentaux de la vie sur Terre, nécessite une gestion efficace pour garantir la durabilité de notre planète. Les barrages, des ouvrages millénaires, ont joué un rôle central dans la gestion de l'eau à travers l'histoire humaine, accomplissant diverses missions telles que la gestion de l'approvisionnement en eau en période de sécheresse, la protection contre les inondations, la production d'énergie hydroélectrique, la rétention des sédiments, et même la création de plans d'eau récréatifs et de voies navigables (Ren et al., 2020). Ces structures multifonctionnelles jouent un rôle clé dans l'équilibre délicat entre les besoins en eau et la gestion des risques associés à cette précieuse ressource.

Au fil du temps, la construction des barrages permanents a connu une impressionnante évolution en utilisant divers matériaux tels que la maçonnerie, le béton, le remblai de terre, l'enrochement, ainsi que parfois le bois ou l'acier. Chacun de ces matériaux présente des avantages et des inconvénients spécifiques en ce qui concerne la conception, la fonction et l'exploitation des barrages (Kutzner, 1997). Au départ, les normes de pratique se sont formées à partir d'expériences empiriques réussies. Cependant, l'histoire des barrages en remblai remonte à des millénaires, avec des réalisations impressionnantes bien avant l'ère moderne. Par exemple, un barrage en remblai monumental, de 11 miles de long, 70 pieds de haut, contenant environ 17 millions de verges cubes de remblai, a été achevé à Ceylan en 504 avant J-C. Cependant, ces premières constructions étaient vulnérables aux inondations, à l'infiltration d'eau, et à d'autres forces destructrices en raison de leur conception rudimentaire (U.S. DI, BR, 1977).

Au cours des cinq dernières décennies, la conception et la construction des barrages en remblai ont connu une évolution significative grâce à l'introduction de méthodes analytiques et expérimentales. Ces méthodes ont permis une approche plus rigoureuse et théorique de la conception des barrages, renforçant ainsi leur sécurité et leur durabilité. Les fondations des barrages en remblai sont souvent constituées de dépôts alluviaux, composés de sables perméables et de graviers recouvrant des formations géologiques imperméables. Ces matériaux perméables varient en taille, du sable fin au gravier, souvent agencés en couches stratifiées. Deux problématiques majeures se posent concernant ces fondations perméables: la quantité d'infiltration traversant la fondation et les forces exercées par l'infiltration sur la structure (Kutzner, 1997).

L'analyse de l'infiltration a pour but de contrôler les pertes d'eau, mais aussi de prévenir les dommages internes causés par l'infiltration à travers la structure et les fondations. Les ruptures de barrages en terre sont souvent liées à des problèmes d'infiltration non maîtrisée, soulignant l'importance cruciale de la gestion de l'infiltration. La conception des barrages en terre doit accorder une attention particulière à ce paramètre, et l'analyse de son impact constitue un aspect crucial de ce processus. Traditionnellement, l'analyse de l'infiltration reposait sur des méthodes empiriques et expérimentales, mais celles-ci présentent des limites en termes de coût, de temps et de précision. Les processus d'infiltration sont souvent non linéaires et complexes, rendant difficile le développement de modèles précis avec les méthodes classiques. Parallèlement à ces avancées dans le domaine de l'hydrologie et de l'ingénierie des barrages, l'intelligence artificielle (IA) est apparue comme un domaine contemporain transcendant les frontières de la science et de la technologie. L'IA, avec ses sous-domaines tels que l'apprentissage automatique et la logique floue, offre de nouvelles perspectives pour comprendre et modéliser des phénomènes complexes. Depuis sa création, l'IA a été utilisée pour résoudre divers problèmes, allant de la maîtrise du jeu d'échecs à la conduite automobile autonome en milieu urbain dense. L'IA promet de transformer notre manière de penser, de résoudre des problèmes et d'interagir avec un monde complexe qui nous entoure.

Dans ce contexte, l'application de l'IA à la gestion des barrages est un domaine de recherche prometteur. Les méthodes traditionnelles de prédiction du débit de fuite à travers les barrages s'appuyaient sur des équations empiriques ou des modèles physiques, qui pouvaient être coûteux à développer et nécessitaient une collecte de données importante. Toutefois, ces dernières années ont vu l'émergence de modèles de réseaux neuronaux et d'autres techniques d'IA comme des approches efficaces pour prédire le débit de fuite. Ces modèles sont capables de modéliser des relations non linéaires complexes entre les variables d'entrée et de sortie, offrant ainsi une meilleure précision dans la gestion des barrages.

Cette thèse est focalisée sur l'utilisation de l'intelligence artificielle pour prédire le débit de fuite à travers cinq barrages situés dans le nord de l'Algérie telles que (Barrage Bougous, Barrage Chaufas Mascara, Barrage Zit Emba, Barrage Oued Cherf, Barrage Bouhamdane). Elle explore également l'application de l'IA pour comprendre les mécanismes d'infiltration à travers les barrages en remblai, en évaluant différentes méthodologies d'IA telles que les réseaux neuronaux, les systèmes Neuro-Flou adaptatif (ANFIS), la Machine à vecteurs de support des moindres carrés (LSSVM), la Régression multivariée par Spline adaptative (MARS) et le M5Tree. À travers ces analyses, cette thèse vise à contribuer à une meilleure compréhension de

la modélisation des flux d'infiltration et de la prédiction du débit de fuite, renforçant ainsi la sécurité et l'efficacité des barrages. Cette thèse est structurée en plusieurs chapitres, chacun explorant un aspect spécifique de la modélisation de l'infiltration dans les barrages. Chaque chapitre propose une analyse approfondie des méthodes, des données et des résultats, contribuant ainsi à l'avancement des connaissances dans ce domaine crucial de l'ingénierie hydraulique.

- Le premier chapitre est consacré à une présentation et des généralités sur les barrages en terres.
- Dans le deuxième chapitre nous avons présentés la base de données utilisée et la description des barrages réservoirs objet de la présente étude.
- Dans le troisième chapitre nous avons présentés la description des modèles à base d'intelligences artificielles.
- L'état de l'art des différents travaux déjà publier sur l'utilisation de intelligences artificielles a fait l'objet de quatrième chapitre.
- Les résultats de la modélisation par les différents modèles à fait l'objet des chapitres 4, 5, et 6.

En conclusion, cette thèse présente une contribution significative à la compréhension des phénomènes d'infiltration dans les barrages, soulignant l'importance croissante de l'IA dans l'ingénierie hydraulique. Les résultats et les méthodologies développés dans ce travail contribuent à l'amélioration de la sécurité et de la durabilité des barrages, tout en enrichissant notre compréhension de l'impact de l'infiltration sur ces infrastructures essentielles.

---

***Chapitre I : Généralités sur les Barrages en Terres***

---

## I.1. Introduction

Les barrages, structures qui servent à stocker l'eau pour l'utiliser pendant les périodes de sécheresse ou pour protéger les zones terrestres, représentent l'une des plus anciennes structures d'ingénierie de la civilisation. À l'heure actuelle, les barrages sont une composante essentielle des systèmes d'alimentation en eau, des installations hydroélectriques et des projets de contrôle des inondations. Les barrages peuvent également servir à créer des réservoirs à des fins récréatives et de navigation et pour la rétention des sédiments. Un barrage sert souvent d'installation polyvalente. Les barrages comme installations permanentes sont généralement construits en maçonnerie, en béton, en remblai de terre ou en enrochement, bien que le bois et les matériaux en acier puissent également être utilisés. Certains avantages et inconvénients sont associés à la construction, à la fonction et à l'exploitation des barrages construits avec chacun de ces matériaux.

Les barrages en remblai pour le stockage de l'eau ont été utilisés depuis les premiers jours de la civilisation, comme en témoignent l'histoire et les ruines des cultures passées. Certaines de ces structures construites dans l'antiquité étaient de taille considérable. Un barrage en remblai, qui mesurait 11 milles de long et 70 pieds de haut et contenait avec environ 17 millions de verges cubes de remblai, a été achevé à Ceylan en 504 avant J-C. (U.S. DI, BR, 1977). Les premiers barrages ont été construits simplement en entassant des matériaux de terre à travers la zone à bloquer avec la circulation humaine produisant souvent tout le compactage. Plusieurs ont été détruites par le débordement, infiltration, ou d'autres forces destructrices. Des normes de pratique ont finalement émergé qui n'avaient aucun fondement théorique, sauf qu'une méthode avait fonctionné à plusieurs endroits. Au cours des 50 dernières années, les méthodes analytiques et expérimentales ont joué un rôle important dans la conception et la construction de barrages en remblai.


Les fondations des barrages en remblai sont souvent constituées de dépôts alluviaux, composés de sables relativement perméables et de graviers recouvrant des formations géologiques imperméables. Les matériaux perméables peuvent varier en taille du sable fin au gravier et sont généralement constitués de mélanges stratifiés. Deux problèmes fondamentaux se trouvent dans les fondations perméables. L'un concerne la quantité d'infiltration à travers la fondation et l'autre concerne les forces exercées par l'infiltration sur la structure. Le contrôle de la perte d'eau n'est pas la seule raison d'analyser les infiltrations. (Justin, 1932) a compilé les ruptures de barrages en terre et parmi celles qui n'ont pas échoué à cause du débordement, environ 80% ont échoué à cause de la tuyauterie, de la desquamation à l'orteil ou d'autres

résultats d'infiltration incontrôlée. (Horsky, O, 1969) a fait état d'un réservoir construit sur une fondation calcaire dont le taux d'infiltration était si élevé que le réservoir ne retenait pas l'eau. Un pourcentage élevé des ruptures de barrages de terre signalées par (Sherard et al., 1967) étaient également des ruptures d'infiltration. Par conséquent, le plus grand besoin de conception, après avoir envisagé le débordement, est de prévenir les dommages internes causés par l'eau qui s'infiltré à travers le bain de la structure et des fondations. Les méthodes d'analyse de l'influence des infiltrations sont parmi les aspects les plus importants de la conception et de la construction de barrages en terre.

## I.2. Historiques

La construction des barrages est l'une des plus anciennes activités techniques appliquées au profit de grands groupes humains. Les barrages en terre et enrochement sont connus depuis le 3ème millénaire avant Jésus-Christ. (Schnitter, 1987) nomme pas moins de 34 structures de barrage existant au début de notre chronologie dans toutes les civilisations des temps anciens. Le plus grand d'entre eux mesurait 30 m de hauteur. Même à notre époque, cela serait défini comme un « *Grand Barrage* ». À la fin du 16<sup>ème</sup> siècle, la liste comprend environ 300 structures, servant presque exclusivement au stockage de l'eau. Bien sûr, l'irrigation des terres, l'approvisionnement en eau et la lutte contre les inondations ont été les fonctions dominantes.

*Sadd-El-Kafara* près du Caire en Égypte, un barrage en enrochement avec un noyau de terre, était l'un des plus anciens barrages du monde, construit vers 2600 ans avant J-C. Le barrage a été conçu pour le contrôle des inondations. Ce barrage formait un réservoir d'eau de retenue qui répondait aux besoins d'une carrière d'albâtre à une distance de 3 km. Il mesurait 12 m de haut et 106 m de long. Même si sa largeur était énorme (**Figure I.1**), en raison de sa mauvaise structure, le barrage a cédé dans les premières années de son service, probablement en raison du débordement de l'eau de la crête, et les extrémités du barrage (culées) sont visibles encore aujourd'hui (Norman, 1971; Schnitter, 1994).



**Figure I. 1.** Section transversale du barrage Sadd-El-Kafara. (Tanchev, 2014)

Dans les temps anciens, d'autres barrages avaient également été construits. Au milieu du III<sup>e</sup> millénaire avant J-C, au nord de Bagdad, avait été construit le barrage de Nimrud, probablement un barrage en terre, au moyen duquel le cours du fleuve Tigris avait été détourné. Le barrage a cédé en 1200 avant J-C, et par la suite, le Tigre est retourné à son ancien chenal fluvial. Une autre structure importante était le barrage de remblai Marib, de 7 m de hauteur, dans le nord de Yamen près de la ville de Marib. Le barrage servait de terre irrigation. Il a été construit en 750 avant J-C. Il avait été utilisé pendant plus de 1000 ans quand il a été détruit dans la 2<sup>ème</sup> moitié du 6<sup>ème</sup> siècle. Son dépassement est mentionné dans la 34<sup>ème</sup> sourate du Coran comme une punition de Dieu au peuple qui avait abjuré sa foi. Ce barrage faisait partie d'un système d'irrigation pour une superficie d'environ 1600 hectares de terres agricoles afin de fournir de la nourriture à environ 300 000 personnes, à cette époque et dans cette région de la reine de Saba (Jenner, 1983). Un nouveau barrage a été construit à notre époque sur la même rivière à une centaine de mètres en amont pour irriguer à nouveau la région.

Les activités de construction de barrages ont augmenté rapidement avec le développement industriel. Dans la région du Harz en Allemagne, 60 barrages de remblai avaient été construits jusqu'au milieu du 17<sup>ème</sup> siècle en relation avec les industries minières (Schmidt, M, 1989). Une étape importante du développement consiste à appliquer un sol cohésif en tant qu'élément d'étanchéité interne. Cette nouvelle méthode offrait les avantages d'une meilleure protection et de moins de travaux de réparation de l'étanchéité après une attaque destructrice par des animaux et de la glace. Jusqu'à présent, le nombre total de structures de barrage de tous types est passé à environ 35 000, où les plus hauts barrages Nurek à 300 m et Rogun à 332 m dans l'ex-URSS sont constitués de roche et de sol. Contrairement à d'autres domaines d'activité technique, au cours des millénaires, la construction de barrages a suivi l'intuition plutôt que des règles scientifiques. Ce n'est qu'au tournant du siècle dernier que les considérations scientifiques de la mécanique des sols et des techniques de construction ont abouti aux performances exceptionnelles de l'ingénierie moderne des barrages. Un crédit substantiel est dû à Wolmar Fellenius (1919) et à son développement des calculs de cercles de diapositives et à Karl (Terzaghi, 1925) et à son « Erdbaumechanik auf bodenphysikalischer Grundlage ». Le développement ultérieur est marqué par l'augmentation de la recherche sur les phénomènes mécaniques du sol, résumée par (Breth, 1972) comme suit:

- Érosion des sols par rapport à leur protection par des filtres,
- La teneur en eau des sols cohésifs par rapport à la compactabilité,

- Résistance au cisaillement des sols cohésifs par rapport à la pression de l'eau interstitielle,
- Comportement de déformation non linéaire des sols par rapport à l'état triaxial de contrainte et de déformation.

La recherche scientifique à cet égard a permis d'accroître la confiance de la profession et du public dans l'ingénierie des barrages et son évolution après la 2ème guerre mondiale. Les considérations des géotechniciens sont maintenant principalement axées sur la stabilité à l'érosion, sur la déformation des barrages pendant la construction et l'exploitation des réservoirs et sur la sécurité contre la fissuration, en plus de la stabilité statique et dynamique. Les considérations de contrainte et de déformation ont été améliorées essentiellement par le développement de calculs statiques et dynamiques basés sur des éléments finis, en ce qui concerne le comportement non linéaire des matériaux de terre et rocheux. Les méthodes statiques couvrent tous les cas de charge conventionnels, tandis que les méthodes dynamiques simulent l'effet des charges sismiques. De tels calculs ont été développés principalement aux États-Unis. (Seed, 1979) en font des commentaires détaillés à leur sujet. Malheureusement, il est assez coûteux d'utiliser pleinement de telles méthodes. En parallèle, des instruments de mesure ont été développés pour contrôler les contraintes et les déformations dans les barrages existants. Aujourd'hui, il est courant d'équiper toutes les structures de barrage d'instruments appropriés et d'évaluer les valeurs mesurées en continu. L'état actuel de la technique nous permet de construire de grands barrages de remblai dans un délai raisonnable et à des coûts justifiables. Cela est dû à la grande capacité de tous les équipements de terrassement et des machines de compactage donnant un maximum de densité et donc de résistance au cisaillement à tous les matériaux de construction pertinents. La vue typique d'un site de barrage moderne est marquée par une flotte de machines autonomes exploitées par un minimum de personnes.

### **I.3. Types de Barrages en Remblai**

Les barrages en remblai sont construits de matériaux naturels excavés ou obtenus dans les environs sans aucune liaison. Il existe deux principaux types de barrages de remblai : les barrages en terre et les barrages enrochement en fonction des matériaux utilisés sur le remblai. Un barrage de remblai peut être caractérisé comme un barrage en terre si les sols compactés représentent plus de 50% du volume de matériau placé. Un barrage de remblai en terre est construit principalement à partir de sols d'ingénierie sélectionnés compactés uniformément

et intensément en couches relativement minces et à une teneur en humidité contrôlée. Ils se composent généralement d'un noyau imperméable fait de sols argileux, de filtres et de drains généralement faits de sol sablonneux et graveleux pour empêcher le noyau d'être lavé. (Norak et al., 2007).

### **I.3.1. Barrage Homogène**

Les barrages appelés « barrages homogènes » sont le prototype de barrages construits depuis des millénaires pour protéger les personnes et les terres cultivées des inondations et pour créer des réservoirs d'eau. Ils sont essentiellement d'un seul type de sol (**Figure I.2.A**). Le matériau de construction principal doit être imperméable dans un sens pratique. Cela signifie que les sols principalement cohésifs comme le limon et l'argile sont pris en compte, ayant une perméabilité d'environ  $10^{-7}$  m/s. De tels sols ne développent pas une résistance élevée au cisaillement, de sorte que les pentes extérieures sont plates dans la plage de (1/2.5 à 1/5). Les pentes plates sont liées aux zones de fondation larges et donc aux grands volumes de barrage. La hauteur est donc limitée, pour des raisons pratiques, à environ 30 à 35 m (Kutzner, 1997).

### **I.3.2. Barrage Zoné**

Les barrages zonés sont constitués de plus d'un type de matériau de construction. L'élément d'étanchéité ne couvre pas toute la section transversale (**Figure I.2.B**). D'autres zones du barrage sont constituées de matériaux de plus grande résistance au cisaillement. Il en résulte principalement deux avantages :

- Des sols non cohésifs peuvent être utilisés, qui sont plus faciles à manipuler sur place. Ils permettent une production quotidienne accrue dans la construction du remblai.
- La résistance au cisaillement plus élevée des matériaux non cohésifs entraîne des pentes extérieures plus raides et une réduction du volume des barrages par rapport aux barrages homogènes.

Le zonage découle principalement du type et de la disponibilité des matériaux. Un optimum est un zonage où la perméabilité augmente des parties intérieures vers les parties extérieures. Ceci est, généralement, lié à la diminution de la déformabilité de la partie interne vers les parties extérieures, Les deux sont atteints, par exemple, avec le barrage d'Aabach dans la **Figure I.2.A** (Kutzner, 1997).

### **I.3.3. Barrages en enrochement**

Ce type de barrage est une version presque idéale des grands barrages (**Figure I.2.D**). Outre le noyau imperméable et les matériaux d'enrochement à drainage libre, seuls le gravier et

le sable pour les filtres sont nécessaires. Fréquemment, la section typique est modifiée en utilisant d'autres matériaux provenant d'excavations, tels que la dérivation, le déversoir, la centrale électrique et l'excavation des fondations. La conception du barrage doit être adaptée à la qualité de ces matériaux (Kutzner, 1997). Le prototype est le barrage de matériau d'enrochement à drainage libre de haute qualité avec un noyau de terre imperméable. Deux variantes existent :

- Le noyau est disposé symétriquement autour de la ligne centrale du barrage (**Figure I.2.D**). C'est ce qu'on appelle un barrage avec un noyau vertical, car la ligne centrale du noyau est verticale,
- Le noyau est incliné. C'est ce qu'on appelle un barrage avec un noyau incliné, car la ligne centrale du noyau est inclinée.

Les barrages en enrochement et en gravier avec des carottes de terre sont très résistants aux tremblements de terre (Seed, 1979; Thomas, 1978).




Figure I. 2. Section transversale de différents types des barrages en remblais. (Kutzner, 1997)

## I.4. Critères de Conception

Un barrage de remblai doit pouvoir supporter en toute sécurité les charges statiques et dynamiques qui peuvent lui être imposées pendant sa durée de vie. Cette unité fournit une vue d'ensemble pour évaluer la stabilité du barrage de remblai, notamment :

- Exigences en matière d'évaluation de la sécurité.
- Effet de l'infiltration sur la stabilité du barrage en remblai
- Comportement de remblai.

Les barrages en remblai ont été construits depuis les premiers temps. La philosophie générale dans la conception de ces barrages a été d'utiliser des matériaux géologiques disponibles localement. Les pratiques de conception ont évolué avec une meilleure compréhension du comportement du sol. Les techniques de construction ont évolué avec les progrès de l'équipement de terrassement et de compactage (USBR, 1991).

Les barrages en remblai sont un choix privilégié pour les sites avec de larges vallées et des conditions de fondation difficiles en raison de leur flexibilité.

Tous les projets doivent tenir compte des conditions régionales et locales. Pour la construction de barrages, les conditions suivantes doivent être respectées :

- Géologie
- Morphologie et topographie,
- Hydrologie.

Au début, des études et des enquêtes approfondies sont nécessaires sous ces rubriques, qui durent généralement plusieurs années. Comme on le sait, les incidents de barrages provoquent des catastrophes humaines et des revers économiques dans une large mesure. Des enquêtes statistiques sur les ruptures de barrages ont été menées pour évaluer l'origine de ces incidents. Un nombre remarquable de défaillances a été causé par des investigations insuffisantes et par une mauvaise interprétation des conditions géologiques et hydrologiques. Ceci est confirmé par les dernières statistiques de la ICOLD (1974)

### I.4.1. Géologie

Les conditions géologiques d'un site particulier rendent un projet réalisable ou non: les conditions de fondation doivent être adéquates et la majeure partie des matériaux de construction requis doit être disponible à une courte distance. Sans ces conditions préalables, le site peut être irréalisable. Tous les aspects sismiques sont généralement attribués à la géologie. Les conditions sismiques doivent être étudiées par région et par zone (pas seulement localement) pour permettre la définition du séisme de base opérationnelle (OBE) et du séisme

maximal crédible (MCE) qui conviennent au site. Les études respectives devraient couvrir les temps passés, dans la mesure du possible, car les événements sismiques du passé fourniront des informations précieuses.

#### **I.4.2. Morphologie et Topographie**

La morphologie, c'est-à-dire la forme et la structure de la surface de la terre, est un autre critère pour choisir un site de barrage. Pour les barrages en remblai, le critère se limite à trouver l'emplacement le plus approprié parmi plusieurs choix. La topographie du site du barrage et de la zone du réservoir est une question de levé géodésique. La topographie de la zone en question doit être étudiée au plus tard au moment où le site le plus approprié doit être sélectionné. La topographie est la base de la courbe de remplissage du réservoir. Dans les pays en développement, l'enquête est généralement réalisée par photogrammétrie aérienne, d'une à cinquante mille ou d'une échelle similaire. Dans des conditions de végétation dense, une tolérance allant jusqu'à 10 m de hauteur doit être prise en compte. Un levé de surface plus précis n'est souvent effectué qu'au moment où l'emplacement du barrage a été sélectionné.

#### **I.4.3. Hydrologie**

Les aspects hydrologiques ne sont traités ici que dans la mesure nécessaire à une meilleure compréhension. L'hydrologie est liée à la construction des barrages et à l'exploitation des réservoirs par la nécessité de détourner les rivières pendant la construction de barrages et par le contrôle des inondations. La prévision des événements hydrologiques est nécessairement basée sur les données disponibles des temps précédents. Une prédiction correcte bénéficie de la durée de la période qui est couverte par des données précises et fiables. Dans les régions éloignées, ces périodes peuvent être courtes. Ceci, généralement, se traduit par des dimensions généreuses des structures pour le contrôle des inondations. Les critères communs pour la conception des réservoirs sont l'inondation maximale probable (PMF) et la capacité de rétention du réservoir. Dans certains projets, le PMF est remplacé par l'inondation de 10 000 ans. Pour les PMF, il existe une gamme extrême d'inondations à contrôler. Les structures construites dans les rivières détournantes sont conçues selon des données hydrologiques, mais pas exclusivement. Les critères supplémentaires sont la durée de la période de construction et l'acceptation d'un risque restant d'inondation du chantier. Encore une fois, il y a un large éventail d'inondations de construction à contrôler.

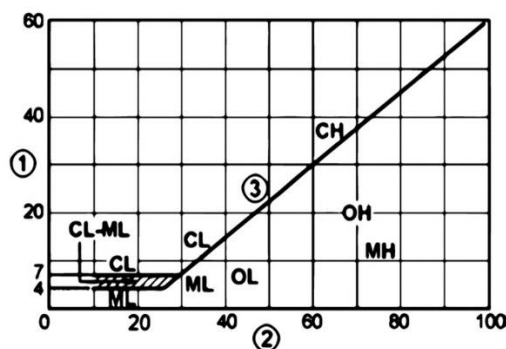
#### **I.5. Matériaux de Construction**

Les conditions qui devraient être remplies par les matériaux locaux pour la construction des barrages en remblai dépendent du type de barrage, de son emplacement et du rôle du

matériau dans la section transversale du barrage, ainsi que de la méthode d'exécution du barrage. Dans le même temps, il convient de prendre en considération les caractéristiques physiques et mécaniques des matériaux locaux, les conditions climatiques de la localité dont dépendent les méthodes de construction, l'emplacement des fosses d'emprunt et les modes d'utilisation, de transport et d'incorporation des matériaux. Il existe différentes classifications du matériau du sol, mais celle proposée par (Casagrande, 1948) et adoptée en 1952 par l'USBR et l'USCE est largement utilisée. Cette classification des sols cohésifs est basée sur la distribution granulométrique, la limite de liquide et l'indice de plasticité (**Figure I.3 et Tableau I.1**). Le système comprend également des matières grossières (**Tableau I.1**). Ce système de classification permet d'estimer l'étendue des propriétés et de la perméabilité des sols. Ainsi, c'est un outil puissant entre les mains d'ingénieurs géotechniques expérimentés.

**Tableau I. 1.** Symboles de groupe et noms typiques des sols (USBR, 1984).

| Symboles de groupe | Noms typiques et critères de classification du laboratoire  |
|--------------------|---|
| GW                 | Gravier bien calibré, mélanges gravier-sable; peu ou pas d'amendes. CU supérieure à 4   |
| GP                 | Gravier mal classé, mélanges gravier-sable; peu ou pas d'amendes. Ne répond pas à toutes les exigences de gradation pour GW.    |
| GM                 | Gravier limoneux, mélanges gravier-sable-limon mal classés. Atterberg limite en dessous de la ligne A, ou PI inférieur à 4.     |
| GC                 | Gravier argileux, mélanges gravier-sable-argile mal classés. Atterberg limite au-dessus de la ligne A avec un PI supérieur à 7. |
| SW                 | Sables bien classés, sables graveleux; peu ou pas d'amendes. CU supérieure à 6.   |
| SP                 | Sables mal classés, sables graveleux; peu ou pas d'amendes. Ne répond pas à toutes les exigences de gradation pour SW           |
| SM                 | Sables limoneux, mélanges sable-limon mal classés. Atterberg limite en dessous de la ligne A, ou PI inférieur à 4.              |
| SC                 | Sables argileux, mélanges sablo-argileux mal classés. Atterberg limite au-dessus de la ligne A avec un PI supérieur à 7.        |
| ML                 | Limons inorganiques et sables très fins, farine de roche, sables fins limoneux ou argileux à légère plasticité.                 |
| CL                 | Argiles minérales de plasticité faible à moyenne, argiles graveleuses, argiles sableuses, argiles limoneuses, argiles maigres   |
| OL                 | Limons organiques et argiles limoneuses organiques de faible plasticité.  |
| MH                 | Limons inorganiques, sols sableux ou limoneux micacés ou diatomées, limons plastiques.  |
| CH                 | Argiles minérales de haute plasticité, argiles grasses.   |
| OH                 | Argiles organiques de plasticité moyenne à élevée.  |
| PT                 | Tourbe et autres sols hautement organiques.   |



**Figure I. 3.** Diagramme de classification des sols cohésifs (Unified Soil Classification Chart, adapté de (Kutzner, 1997)). (1) Indice de plasticité, (2) limite de liquide (%) and (3) A-line.

La ligne (A) sépare les argiles des limons (**Figure I.3**), et seules les argiles organiques (OL et OH) se trouvent sous la ligne A, c'est-à-dire du côté du limon. Ils ne conviennent pas comme matériaux de construction dans l'ingénierie des barrages. Le système complet comprend 15 symboles de groupe (**Tableau I.1**). Il couvre tous les types de sols qui conviennent à l'ingénierie des barrages. Pour un choix correct de la structure d'un barrage et des méthodes de construction, nous pouvons en pratique utiliser tous les matériaux locaux, à l'exception des matériaux terrestres contenant des quantités inadmissibles de matière organique et de sels solubles dans l'eau. Les éléments de terre imperméables à l'eau (noyau, parement, tablier amont, dents verticales) sont fabriqués à partir de matériaux peu perméables à l'eau, avec un coefficient de perméabilité de  $k \leq 10^{-5}$  cm/s. Le meilleur matériau à cet effet est l'argile avec une humidité proche de l'optimum ou un peu plus élevée. Dans certains cas, dans la construction d'éléments imperméables à l'eau, il est également possible d'utiliser un mélange artificiel de terre argileuse, sableuse et graveleuse, constitué sur la base d'études expérimentales. Les coquilles de la roche terrestre et le corps des barrages en enrochement peuvent être fabriqués à partir de matériaux naturels à gros grains. Pour l'évaluation de la qualité des matériaux locaux à gros grains, leur composition pétrographique, leurs propriétés physiques et mécaniques et leur composition chimique sont essentielles (Vallejo, 1995). Le matériau d'enrochement doit être bien calibré et un excellent matériau pour la construction de barrages à la distribution granulométrique suivante :

1. Pas plus de 5 % en dessous de 5 mm;
2. Pas plus de 30 % en dessous de 20 mm;
3. Granulométrie maximale de 600 à 1000 mm, en fonction de la résistance de la roche et de la tendance à la rupture des particules; les dimensions maximales des grains

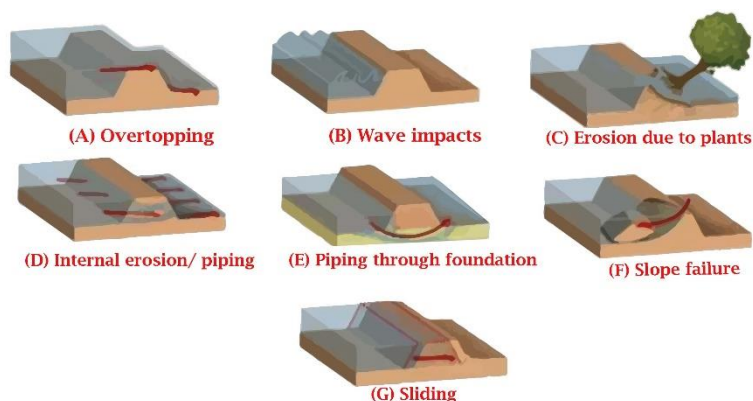
dépendent également des méthodes de construction, ainsi que des installations et équipements disponibles.

4. La perméabilité des matériaux d'enrochement compétents doit être élevée. Ainsi, il s'agit d'un drainage libre, et par conséquent, aucun problème ne se pose avec la pression interstitielle.

Pour la protection des pentes des barrages contre l'action des vagues et les effets des intempéries, il est possible d'utiliser de la pierre provenant de roches ignées, métamorphiques ou sédimentaires, qui répondent aux exigences relatives à la taille des grains et à la résistance. Dans le cas de matériaux cohésifs placés dans le corps du barrage, il est particulièrement important d'obtenir un bon compactage des couches, qui dépend de l'humidité du matériau, de l'installation et de l'équipement utilisés, ainsi que du travail consacré au compactage.

## I.6. Défaillance Des Barrages en Remblai

Les modes de rupture les plus courants des barrages en remblai peuvent être séparés en trois catégories principales : défaillances hydrauliques, d'infiltration et structurelles. Certains de ces mécanismes sont illustrés à la Figure 1.4.



**Figure I. 4.** Modes de défaillance des barrages en remblai.

### I.6.1. Défaillances Hydrauliques

- Débordement (**Figure I.4A**): lorsque le franc-bord du barrage ou la capacité du déversoir est insuffisant, les eaux de crue passeront au-delà de la crête du barrage et provoqueront l'érosion de la crête et du côté aval ([Makra, 2013](#)).
- Érosion du pied en aval: Cela est dû à un fort courant transversal provenant du déversoir ou de l'eau de queue ([Makra, 2013](#)).
- Érosion de la face amont (**Figure I.4B**): Ce mode de défaillance est causé par des ondes à la surface du réservoir ([Makra, 2013](#)).
- Érosion de la face aval (**Figure I.4C**): Cette défaillance est causée par l'altération de la

taille due à de fortes pluies ou à des animaux et à des plantes (**Figure I.4B**).

### I.6.2. Échecs D'infiltration

- Tuyauterie à travers le corps du barrage (**Figure I.4D**) : Pendant l'infiltration, de petits canaux peuvent se former qui transportent les matériaux en aval et augmentent progressivement ([Makra, 2013](#)).
- Tuyauterie à travers les fondations: si dans la fondation du barrage il y a des cavités très perméables, des fissures, des infiltrations concentrées à un taux élevé se produisent. Cela entraîne une érosion et un écoulement de l'eau et du sol dans les fondations (**Figure I.4D**).
- Affaissement du côté aval du barrage : Le pied aval du barrage devient saturé et commence à s'éroder, provoquant un petit effondrement ou glissement du barrage qui peut progressivement progresser et conduire à la rupture.

### I.6.3. Défaillances Structurelles

- Glissade dans le remblai : Si l'une des pentes du remblai est trop raide, elle peut être glissante. Pour la pente u/s, cela est généralement déclenché par un rabattement soudain (**Figure I.4F**).
- Glissade de fondation: Ce mode de défaillance se produit si la fondation est composée de sol meuble et peut entraîner le glissement de l'ensemble du barrage en raison de la poussée de l'eau (**Figure I.4G**).
- Rupture du séisme de terre : La charge sismique peut entraîner la rupture du barrage lui-même, mais aussi de la fondation et des structures annexes ([Makra, 2013](#)).


## I.7. Stabilités.

La stabilité du talus est contrôlée par les résistances au cisaillement des matériaux du barrage et de la fondation. La preuve est selon la théorie de la défaillance de [Coulomb \(1776\)](#) qui est appliquée aux plans de glissement circulaires ou autrement courbes ou polygonaux. La théorie de la défaillance s'est avérée applicable aux matériaux de construction courants. Avec un barrage homogène sur une fondation équivalente (**Figure I.5A**), la pente elle-même est le plan de glissement critique, à condition que la résistance au cisaillement soit donnée uniquement par frottement. En revanche, le plan critique traverse le barrage si la résistance au cisaillement est donnée par le frottement et la cohésion.

Avec un barrage zoné ayant un noyau de terre sur une fondation de résistance au cisaillement égale ou supérieure, le plan de glissement critique touche la ligne de fondation (**Figure I.5B**). Au voisinage du pied du barrage, la tangente est horizontale, étant donné la

résistance réduite de la fondation, le plan de glissement en profondeur critique traverse le barrage et la fondation (**Figure I.5C**). Il affleure à la surface à l'extérieur du barrage. En raison de la composante horizontale des contraintes dans la ligne de fondation, le pied du barrage a tendance à s'éloigner du centre du barrage. La résultante des contraintes horizontales est appelée force d'écartement. Avec un déplacement trop important, la pente doit être aplatie ou une berme stabilisatrice doit être ajoutée à l'orteil. Les forces d'étalement existent également, mais elles sont négligeables ou presque négligeables, étant donné les mêmes résistances au cisaillement du barrage et de la fondation.

La rupture se produit lorsque les forces motrices le long du plan de glissement dépassent les forces de résistance, la masse au-dessus du plan de glissement glisse (**Figure I.5C**). De grandes déformations se produisent. Le mouvement de glissement s'arrête lorsqu'une nouvelle configuration du système constitue un nouvel équilibre des forces.



**Figure I. 5.** Stabilité du talus & Emplacement des plans de glissement critiques (Kutzner, 1997)

- a. Barrage et fondation homogènes avec une résistance au cisaillement égale
- b. Barrage zoné, la résistance au cisaillement de la fondation est supérieure à celle du corps du barrage
- c. Barrage zoné, la résistance au cisaillement de la fondation est plus faible que celle du corps du barrage
- d. Conditions de défaillance
  - 1.a- Plan de glissement critique, frottement uniquement
  - 1.b- Plan de glissement critique, frottement et cohésion

- 2- Coquille
- 3- Répartition des forces
- 4- Masse de glissement

## I.8. Les Fuites


Tous les barrages en terre et enrochement sont sujets à des infiltrations à travers le remblai, les fondations et les culées. Le contrôle des infiltrations est nécessaire pour éviter les pressions de soulèvement excessives, l'instabilité de la pente en aval, la tuyauterie à travers le remblai et / ou la fondation et l'érosion du matériau par migration dans les joints ouverts de la fondation et des culées. Le but du projet, c'est-à-dire le stockage à long terme, le contrôle des inondations, etc., peut imposer des limites à la quantité permise d'infiltration. Les trois méthodes de contrôle des infiltrations dans les remblais sont les pentes plates sans drains, le zonage des remblais et les drains verticaux (ou inclinés) et horizontaux

### I.8.1. Infiltration à Travers la Digue

L'eau s'infiltré à travers chaque barrage. L'une des tâches de conception et de construction est de rendre la structure fonctionnelle en ce sens que l'eau est correctement évacuée et que la quantité d'eau drainée est tolérable et faible. Cela signifie que:

- Les eaux d'infiltration ne doivent pas mettre en danger la stabilité du barrage. L'érosion des fines doit être exclue. L'érosion peut entraîner des tuyauteries, un grossissement progressif de la perméabilité des zones de barrage associées, des fuites et déformations intolérables et des ruptures.
- La quantité d'infiltration ne doit pas affecter la vie humaine ou toute activité dans la zone aval, comme l'agriculture et l'approvisionnement en eau. La quantité ne doit pas nuire au fonctionnement économique du réservoir. Il est évident que la quantité tolérable ne dépend pas seulement des conditions du système de barrage et de fondation, mais aussi de la quantité totale d'eau à gérer et du volume du réservoir (Kutzner, 1997).

La ligne phréatique dans un barrage homogène est représentée sur la **Figure I.6**. Après saturation du barrage et de la fondation sous la ligne phréatique. Il coupe la pente aval à environ  $1/3$  de la hauteur hydrostatique  $h$ . La perméabilité commande la quantité d'infiltration, qui est proportionnelle à la perméabilité, conformément à la loi de Darcy. Dans la plupart des barrages existants comme dans les sédiments naturels - la perméabilité horizontale est supérieure à la perméabilité verticale, de l'ordre de  $kH$  2 à  $10 \times kV$ . Dans ce cas, l'emplacement réel de la ligne phréatique est décalé en conséquence (**Figure. I.6**).



**Figure I. 6.** Surface phréatique dans un barrage « homogène ». (Kutzner, 1997)


- (1): Surface phréatique,  $kH = kV$
- (2): Surface phréatique,  $kH > kV$
- (3): Berme de drainage

Les infiltrations provoquent généralement une instabilité de la pente et de la tuyauterie. La pente doit être protégée et stabilisée par une berme de drainage comme illustré, ou la ligne phréatique doit être tirée vers le bas par des filtres à l'intérieur du barrage. Les filtres doivent empêcher le passage des amandes. Ils doivent être de taille suffisante pour permettre un drainage libre des eaux d'infiltration.

### I.8.2. Infiltration à Travers la Fondation

L'eau s'infiltré à travers la fondation en dessous et sur le côté de chaque barrage, indépendamment des mesures d'étanchéité artificielles telles que le jointoiment ou le diaphragme. Encore une fois, la conception et la construction sont responsables des fonctions de drainage libre des quantités tolérables d'infiltration et de la stabilité de l'érosion. La couverture filtrante de la **Figure I.7** au fond du barrage, sert à empêcher l'érosion des fines du matériau sous-jacent et des obturations de joints. Si ce filtre est la couche la plus perméable entre la coque et la fondation, il doit être de la bonne taille pour drainer l'eau qui s'infiltré à travers le barrage et s'infiltré à travers la fondation.

1. Ligne phréatique dans le barrage
2. Filtre
3. Lignes d'écoulement dans la fondation
4. Couverture filtrante
5. Trou d'observation des eaux souterraines




**Figure I. 7.** Barrage en enrochement avec noyau de terre vertical. Infiltration à travers le barrage et les fondations après la mise en fourrière. (Kutzner, 1997)

Le remplissage du réservoir conduit d'abord à une saturation de la fondation et des substrats au voisinage du barrage, puis à des infiltrations à travers la fondation et une remontée de la nappe phréatique en aval du barrage. Une élévation de plusieurs mètres a été observée (Kanchanaphol, L et al., 1982; Kutzner, C, 1988). Les infiltrations à travers la fondation ne doivent pas conduire à une déformation nuisible du barrage et de la fondation.

### I.8.3. Drains

Comme il a été mentionné précédemment, des drains verticaux (ou inclinés) et horizontaux peuvent être nécessaires pour contrôler l'infiltration à travers le remblai en empêchant les matériaux érodés par une fissure dans le noyau de s'infiltrer dans l'enveloppe en aval par l'eau d'infiltration sous la tête du réservoir. En outre, en raison des caractéristiques souvent variables des matériaux d'emprunt, il est souvent conseillé de prévoir des drains verticaux (ou inclinés) et horizontaux dans la section aval du remblai, comme le montre la **Figure I.8**, pour assurer un contrôle satisfaisant des infiltrations. Pour un sol stratifié, la perméabilité verticale est contrôlée par la couche la moins perméable. Par conséquent, la perméabilité horizontale est toujours supérieure à la perméabilité verticale.




**Figure I. 8.** Utilisation de drains inclinés et horizontaux pour le contrôle des infiltrations (Brown, 1993)

### I.8.4. Les Caractéristiques Des Filtres.

Les drains verticaux (ou inclinés) et horizontaux devraient être conçus comme des filtres. Si de la roche concassée est utilisée pour le matériau de drainage, si le matériau à protéger est dispersif ou si le matériau à protéger contient des fissures, des essais de filtration seront requis. Les matériaux bien classés sont instables à l'intérieur et ne doivent pas être utilisés comme filtres lorsque le coefficient d'uniformité  $C_u > 20$ .

### I.8.5. Conditions De Décharge.

Les drains verticaux (ou inclinés) et horizontaux doivent avoir des capacités de décharge suffisantes pour éliminer rapidement les infiltrations sans induire de forces d'infiltration élevées ou de pressions hydrostatiques élevées (Cedergren, 1977). Lorsque les drains sont conçus et construits avec une grande capacité d'évacuation, la ligne d'infiltration ne s'élèvera pas au-dessus de la zone de drainage. Étant donné que les drains sont petits par rapport aux dimensions globales du barrage en terre, il est difficile de construire des filets d'écoulement précis à l'intérieur des drains eux-mêmes. La quantité totale d'infiltration provenant de toutes les sources qui doit s'écouler par le drain doit être évaluée à partir d'une analyse du filet d'écoulement dans laquelle on suppose que les drains ont une perméabilité infinie. La **Figure I.9** montre un exemple de la procédure de conception des drains inclinés et horizontaux pour assurer une capacité de drainage adéquate (Cedergren, 1977).



**Figure I. 9.** Conception de drains inclinés et horizontaux pour un drainage optimal. (Brown, 1993)

### I.8.6. Emplacement Et Géométrie.

Les drains verticaux (ou inclinés) sont situés à côté et en aval du noyau. Le sommet du drain doit être au-dessus de la surface phréatique pour une élévation maximale du réservoir afin d'empêcher l'écoulement d'infiltration au-dessus du drain. Si le barrage est situé là où les effets sismiques sont probables, le drain devrait s'étendre sur toute la hauteur du barrage. La largeur du drain est contrôlée par la disponibilité des matériaux et les exigences de décharge du drain. Une largeur de drain verticale (ou inclinée) de 6 pieds est le minimum pratique pour

l'équipement de terrassement et de compactage (USAED.K,1974 ; USAED.P,1974). La largeur du drain vertical doit être suffisante pour satisfaire aux exigences de rejet. Les drains horizontaux sont situés sous la section aval du barrage et transmettent les infiltrations du drain vertical (ou incliné) et les infiltrations de la fondation au pied du barrage. L'épaisseur du drain horizontal doit être suffisante pour satisfaire aux exigences de rejet. Des longerons ou des drains à doigts peuvent être utilisés comme solution de rechange à un drain horizontal continu, lorsque le matériau du drain est coûteux. La section transversale des drains à longerons doit être suffisante pour satisfaire aux exigences de décharge.

## I.9. Les piézomètres

Il est important de contrôler la position de la surface phréatique et le développement des pressions interstitielles dans la fondation et dans le remblai. On peut classer les appareils de mesure en deux types :


- Les piézomètres à tube ouvert dont la longueur crépine est de quelques décimètres à plusieurs Mètres
- Les cellules de pression interstitielle (à corde vibrante, à contre-pression).

Les piézomètres à tube ouvert, peu coûteux et simples à mesurer, sont bien adaptés au suivi d'ouvrages, car ils permettent la détection d'anomalies dans la piézométrie (par exemple, saturation d'un remblai en aval). La mesure se fait à l'aide d'une sonde électrique de 1 cm de diamètre donnant la différence de cote entre la nappe phréatique et la tête du piézomètre qui aura été préalablement nivelée. La tête du piézomètre doit être équipée, d'une part, d'un bouchon étanche empêchant la pénétration des eaux de pluie et de ruissellement, et, d'autre part, d'un dispositif anti-vandalisme afin d'éviter qu'on ne vienne le remplir. Ils sont bien adaptés aux sols modérément perméables et aux roches fissurées. Le temps de réponse du piézomètre est d'autant plus faible que le diamètre du tube est petit. Mais au risque de coincer la sonde de mesure on peut difficilement envisager moins de 2 cm. Les cellules de pression interstitielle fournissent des mesures ponctuelles précises et ont des temps de réponse plus rapides que les piézomètres. Ce sont de petits appareils, placés à l'intérieur du remblai ou de la fondation et qui permettent une mesure locale de la pression interstitielle. Les systèmes de mesure les plus couramment utilisés sur les barrages sont soit hydrauliques (cellule de contre-pression) soit à corde vibrante.


## Piézomètres pour les pressions d'infiltration.

### I.9.1. Fondation.

Pour déterminer la performance des mesures de contrôle des infiltrations, un modèle de comportement doit être établi avant et pendant la construction où les tendances à long terme peuvent être liées aux conditions de conception ou d'infiltration. Les piézomètres doivent généralement être installés dans tous les sols de fondation compressibles, le nombre dépendant de l'étendue et de l'épaisseur des strates. Si possible, les piézomètres de fondation devraient être installés dans les sections sélectionnées pour les piézomètres de remblai et devraient s'étendre au-delà des orteils en amont et en aval à une distance égale à la migration prévue des pressions interstitielles. Un plan d'installation de piézomètre efficace devrait convertir les piézomètres de préconstruction en piézomètres de surveillance des infiltrations post-construction pour une continuité efficace des données. La **Figure I.10A** montre un exemple d'installation de piézomètre avec le remblai reposant sur une fondation de compressibilité et une coupure de noyau imperméable à travers une couche de sable et de gravier. L'efficacité de la coupure et la présence de pressions de soulèvement peuvent être évaluées. La **Figure I.10B** montre un remblai avec un noyau imperméable qui intercepte un sol perméable et repose sur le sommet de la roche et encore une fois l'efficacité de la coupure et / ou l'intégrité de la roche peuvent être évaluées.



A- Exemple d'installation d'un piézomètre de fondation du barrage de Surry Mountain (tiré de l'EM 1110-2-1908)

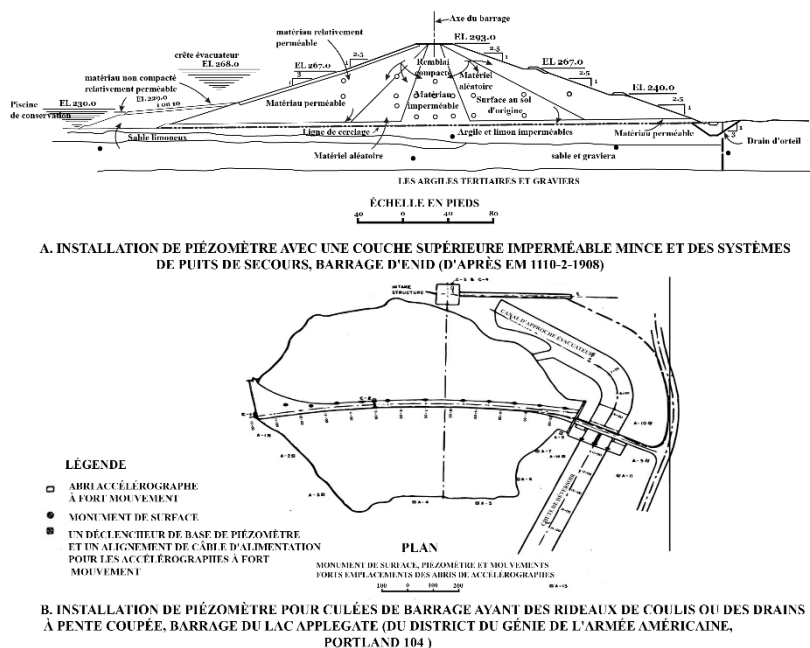


B- Installation de piézomètres pour barrages sur fondations perméables, Deer Creek Dam (d'après EM 1110-2-1908)

**Figure I. 10.** Installation des piézomètres dans la fondation des barrages. (Brown, 1993)

La **Figure I.11A** montre un remblai fondé sur une mince strate supérieure imperméable sous-tendue par une zone profonde de matière perméable. Des écoulements artésiens peuvent

également exister dans les culées et doivent être surveillés. La **Figure I.11B** montre une installation de piézomètre utilisée pour surveiller la coupure d'un rideau de coulis et les drains de pente de coupe. Les mesures correctives de contrôle des infiltrations, pourraient nécessiter des piézomètres supplémentaires pour surveiller à la fois l'installation et l'effet des nouvelles mesures.




**Figure I. 11.** Installation des piézomètres dans couche superficielle. (Brown, 1993)

## I.9.2. Remblai.

Comme il a été mentionné précédemment, trois méthodes de contrôle des infiltrations dans les remblais sont les suivantes : (1) pentes plates avec ou sans drains, (2) zonage des remblais et (3) drains verticaux (ou inclinés) et horizontaux. Un remblai à pentes construit en matériau imperméable et qui a des niveaux de réservoir élevés peu fréquents ne devrait avoir que suffisamment de piézomètres dans le remblai pour établir la surface phréatique. Pour surveiller les mesures de contrôle des infiltrations dans un remblai zoné, le nombre et l'espacement des piézomètres dépendent non seulement de la hauteur du barrage, mais également des propriétés matérielles des zones. En général, les différentes zones devraient augmenter en perméabilité vers l'extérieur et devraient avoir des piézomètres dans chaque zone. Lors du rabattement rapide du réservoir, les piézomètres en amont détecteraient une surpression des pores alors que pendant la conservation et les piscines élevées, tous les piézomètres indiqueraient l'efficacité des zones et vérifieraient les valeurs de conception. Une installation typique dans un remblai zoné est illustrée à la **Figure I.12A**. Dans un remblai zoné, les piézomètres situés près de la face amont du noyau peuvent jouer un rôle déterminant dans le développement de la fissuration dans le


noyau (Vaughan, 1970). La dépression de l'élévation piézométrique dans une zone localisée (cône de dépression) peut indiquer une perte de vitesse de la tête qui indiquerait une fuite à travers le noyau.



**Figure I. 12.** Aménagement de l'installation piézométrique du barrage Baldershead (Brown, 1993)

### I.9.3. Drains.

Le but des drains verticaux (ou inclinés) et horizontaux est de contrôler les infiltrations soit à travers le remblai, soit sous le barrage. Il faut installer suffisamment de piézomètres dans le drain pour déterminer si l'infiltration traverse le matériau du remblai ou s'il s'agit d'un sous-drainage, **Figure I.13A**. Si les drains horizontaux interceptent la sous-infiltration qui, à son tour, est drainée par des drains latéraux, des piézomètres doivent être placés de chaque côté des drains latéraux pour déterminer leur efficacité, **Figure I.13B**. Les tendances à long terme (accumulation de pression ou dépression) détectées dans les drains qui ne sont pas directement liés au niveau du réservoir pourraient indiquer soit des drains bouchés (accumulation de pression) en raison du remblai ou du matériau de fondation se déplaçant dans les drains ou la tuyauterie et l'érosion (dépression) en raison du déplacement de matériaux dans les drains de tuyaux, les zones de haute perméabilité ou dans la roche fracturée. Des piézomètres situés près des tunnels de drainage indiqueraient l'efficacité du tunnel. Les drains à pente coupée peuvent être utilisés pour intercepter les infiltrations et recueillir le drainage le long des pentes de culée, tandis que les piézomètres placés en amont et en aval des drains peuvent déterminer l'efficacité du système de collecte.



**Figure I. 13.** Installation des piézomètres pour barrages avec infiltration et sous-infiltration (Brown, 1993)

### I.9.4. Zones en aval.

Les infiltrations peuvent migrer au-delà de l'orteil du remblai, en particulier dans les schistes argileux ou les formations fissurées. Dans la plupart des cas, la caractérisation des sites géologiques déterminera le besoin de piézomètres en aval de l'orteil, mais sans le moindre doute, ils devraient être installés dans les formations douteuses situées entre 50 et 150 pieds au-delà de l'orteil. Les piézomètres doivent également être installés en aval des travaux de sortie, du déversoir et du bassin de stabilisation s'ils s'étendent bien au-delà de l'orteil et ne sont pas proches des autres piézomètres.

### I.10. Conclusion

A la fin de ce chapitre réservé à la description des différents types des barrages en remblais, leurs méthodes de contrôle des infiltrations et leurs stabilités. Il est nécessaire d'estimer la perte d'infiltration afin d'éviter tout dommage interne causés par celle-ci. L'estimation de la perte par infiltration à travers les barrages en terre a traditionnellement été réalisée par la méthode graphique des filets d'écoulement. Car les méthodes analytiques exactes sont souvent difficiles à appliquer là où il existe des conditions limites complexes. Ces difficultés ont conduit à la mise au point de méthodes numériques permettant l'analyse des infiltrations à l'aide des ordinateurs.

---

## **Chapitre II: Présentation des Barrages Algériens et Description de la Base de Données**

---

## II.1. Introduction

Selon la classification de l'agence nationale des barrages et grands transfert (ANBT), les barrages du nord de l'Algérie sont répartis en quatre régions: la région de l'Est, la région de l'Ouest, la région du centre, et la Région du Chlef. Dans cette étude, nous étudions cinq barrages (barrage Bouhamdane, barrage Bougous, barrage Foug el Khanga, et Barrage Zit Emba) situés dans la région de l'Est, et le barrage de Chaurfas qui est situé dans la région Ouest (**Figure II.1**). Une présentation des différents barrages sera présentée dans ce chapitre. La partie nord algérienne sur les 1500 km de cote vers le sud jusqu'au l'Atlas Saharien est fortement déversée géographiquement notamment par des reliefs particuliers. Le climat de la région est tempéré entre des saisons d'étés secs et chaudes ; autrement des hivers doux et humides ; alors que les précipitations moyennes annuelles dans la zone sont d'environ 600 mm, et peuvent atteindre jusqu'à 1800 mm vers la région l'Est.

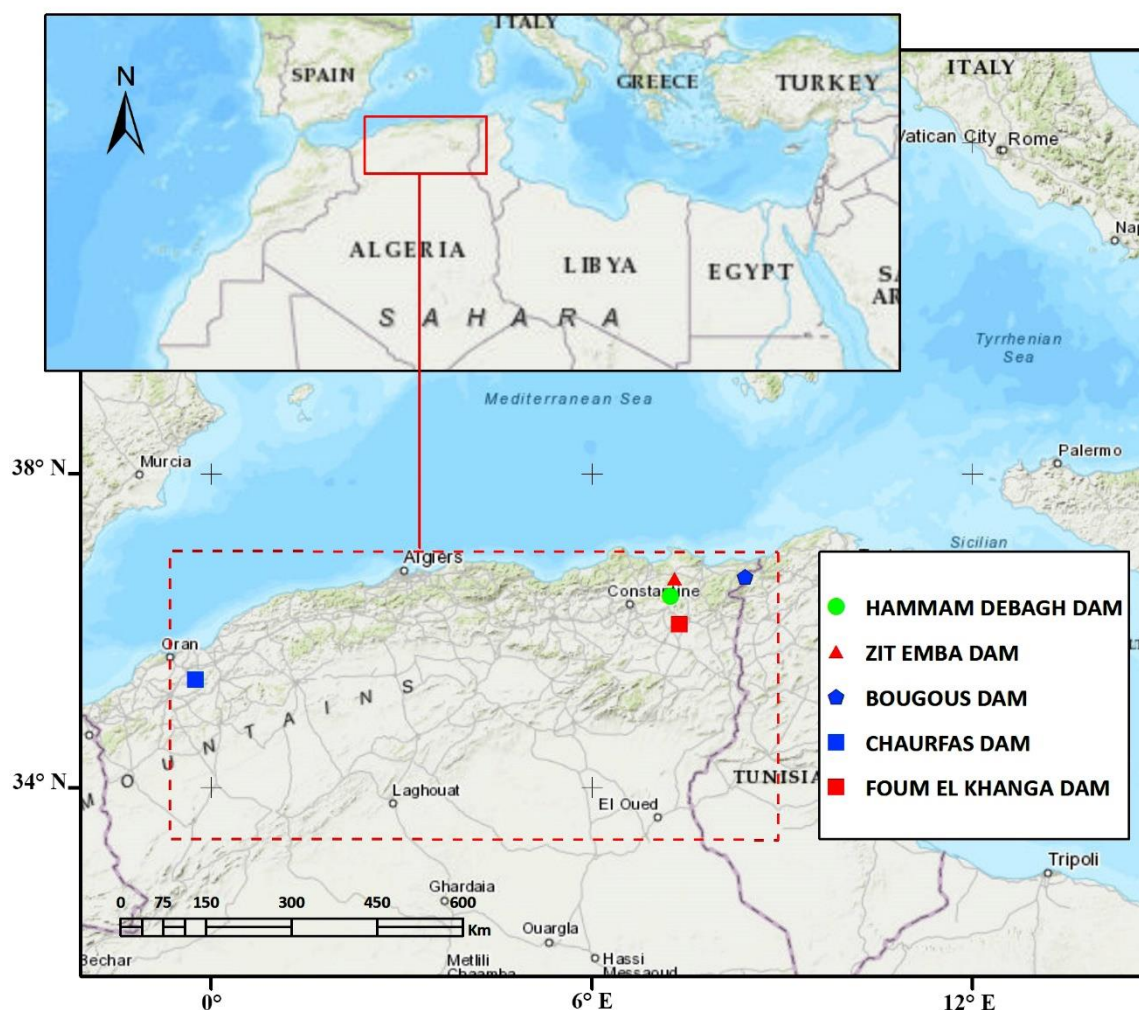


Figure II. 1. Présentation l'emplacement des cinq barrages étudiés.

## II.2. Description des Barrages

Dans cette thèse nous allons étudier 5 cas de barrages en Algérie, ces barrages sont situés dans des endroits différents : barrage Bouhamdane de la Willaya de Guelma (Hammam Debagh), barrage Zit Emba de la Willaya de Skikda, Barrage Chaurfas de la Willaya de Mascara, barrage Fom El Khanga de la Willaya Oum El Baouaghi et barrage Bougous de la Willaya de Tarf (Figure. II.1).

### II.2.1. Barrage Zit el Emba

Le barrage de Zit Emba est situé sur l'Oued Hamman dans la partie Nord-Est de l'Algérie à 2 km de la localité de Bekkouche-Lakhdar, Il est situé sur le territoire de la commune de Bekkouche Lakhdar, dans la daïra de Ben Azzouz, Wilaya de Skikda, avec une capacité totale de 120.106 m<sup>3</sup> (Figure II.2).




Figure II. 2. Situation Géographique du barrage Zit Emba (Skikda).

Il est destiné à l'AEP de la commune d'Azzaba et à l'irrigation d'un périmètre de 6500 ha situé sur la plaine de Ben Azzouz, Il assure une quantité de 8.106 m<sup>3</sup> pour l'alimentation en eau potable (AEP). Il s'étend sur un bassin versant évalué à 485 km<sup>2</sup>. L'altitude maximale est 1200 m, minimale 50 m et moyenne 376 m. Il reçoit une pluviométrie annuelle moyenne de 700 mm. Il a été conçu pour une crue Q<sub>10</sub> de 635 m<sup>3</sup>/s (débit de fréquence 10 ans), crue Q<sub>100</sub> pour 1275 m<sup>3</sup>/s, crue Q<sub>1000</sub> de 1920 m<sup>3</sup>/s, et une crue Q<sub>10000</sub> pour 3060 m<sup>3</sup>/s (Service agricole de Skikda, 2006). Les caractéristiques techniques du barrage Zit Emba sont reportés dans le **Tableau II.1.**

**Tableau II. 1.** Caractéristiques techniques du barrage Zit Emba.

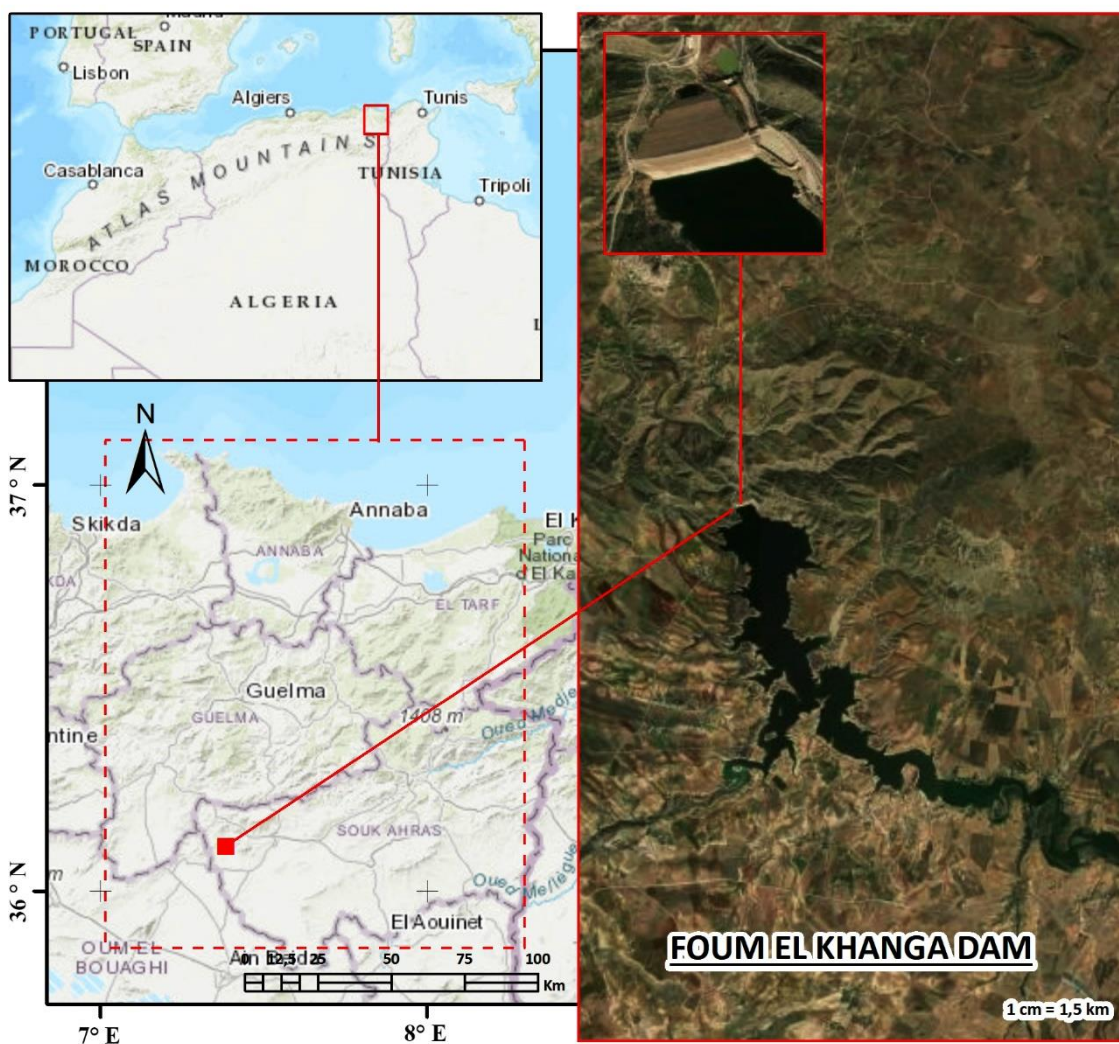
|    |                               |                          |
|----|-------------------------------|--------------------------|
| 01 | Année de construction         | 1989                     |
| 02 | Année de mise en Eau          | 2002                     |
| 03 | Oued                          | El Hammam                |
| 04 | Capacité initiale             | 117.39 hm <sup>3</sup>   |
| 05 | Capacité dernier levé (2003)  | 116.59 hm <sup>3</sup>   |
| 06 | Apport moyen annuel           | 50.0 hm <sup>3</sup>     |
| 07 | Envasement annuel             | 0.24 hm <sup>3</sup> /an |
| 08 | Surface du bassin versant     | 485 Km <sup>2</sup>      |
| 09 | Type                          | Terre                    |
| 10 | Hauteur                       | 47 m                     |
| 11 | Longueur                      | 640 m                    |
| 12 | Côte retenue Normale (R.N)    | 86.00 m                  |
| 13 | Côte Plus Hautes Eaux (P.H.E) | 91.00 m                  |
| 14 | Évacuateur de crue            | Seuil Libre              |
| 15 | Débit d'évacuation            | 1094m <sup>3</sup> /s    |
| 16 | Vidange de Fond               | 68 m <sup>3</sup> /s     |

### II.2.2. Barrage Foum el Khanga

Le barrage de Foum el Khanga est situé sur le territoire de la Wilaya de Oum El Baouaghi, sur l'Oued Charef (Bassin de Seybouse), à 20 km de Sedrata et à 15 km du confluent de l'Oued Charef avec l'Oued Nil (**Figure II.3**). Il est destiné à l'irrigation des terrains agricoles dans la plaine Ksar Sbihi (Souk Ahras-Oum el Baouaghi). Les caractéristiques techniques du barrage Foum el Khanga sont reportés dans le **Tableau II.2.**

**Tableau II. 2.** Caractéristiques techniques du barrage Foum el Khanga.


|    |                               |                          |
|----|-------------------------------|--------------------------|
| 01 | Année de construction         | <b>1987</b>              |
| 02 | Année de mise en Eau          | <b>1995</b>              |
| 03 | Oued                          | CHERF                    |
| 04 | Capacité initiale             | 157,00 hm <sup>3</sup>   |
| 05 | Capacité dernier levé (2004)  | 152,65 hm <sup>3</sup>   |
| 06 | Apport moyen annuel           | 33,0 hm <sup>3</sup>     |
| 07 | Envasement annuel             | 0,52 hm <sup>3</sup> /an |
| 08 | Surface du bassin versant     | 1735 km <sup>2</sup>     |
| 09 | Type                          | TERRE                    |
| 10 | Hauteur                       | 60,0 m                   |
| 11 | Longueur                      | 313,0 m                  |
| 12 | Côte retenue Normale (R.N)    | 745,00 m                 |
| 13 | Côte Plus Hautes Eaux (P.H.E) | 750,00 m                 |
| 14 | Évacuateur de crue            | Seuil Libre              |
| 15 | Débit d'évacuation            | 2 253 m <sup>3</sup> /s  |
| 16 | Vidange de Fond               | 300 m <sup>3</sup> /s    |



**Figure II. 3.** Présentation l'emplacement du barrage Foum el Khanga (Oum El Baouaghi).

### II.2.3. Barrage Bougous

Le barrage Bougous est situé sur l’oued Bougous dans la wilaya d’El Tarf, à 20 km à l’est du Chef-lieu, en bordure de la frontière avec la Tunisie (**Figure II.4**). Le barrage a été réalisé pour satisfaire les besoins en eau potable et industrielle de la wilaya de Tarf et la compensation partielle du volume d’eau suite au réaménagement du barrage de Mexenna situé à l’aval. Il est situé dans la partie Nord-Est de L’Algérie (frontière Algéro-Tunisienne), à 100 Km de la Wilaya d’Annaba et 20 Km à L’Est de la Wilaya d’El-Tarf. Sa construction est sur Oued Bougous qui coule dans la direction Sud-Nord. L’axe du Barrage est situé à 7 Km en amont du barrage Mexenna. L’accès au site se fait par la route qui mène à la commune de Bougous, situé sur la rive gauche de l’oued. Les caractéristiques techniques du barrage Bougous sont reportés dans le **Tableau II.3**.



**Figure II. 4.** Présentation l’emplacement du barrage Bougous (Tarf).

**Tableau II. 3.** Caractéristiques techniques du barrage Bougous.

|    |                               |  |
|----|-------------------------------|--|
| 01 | Année de construction         | <b>2005</b>                                  |
| 02 | Année de mise en Eau          | <b>2010</b>                                  |
| 03 | Oued                          | Bougous                                      |
| 04 | Capacité initiale             | 69.50 hm <sup>3</sup>                        |
| 05 | Capacité dernier levé         | 65.00 hm <sup>3</sup>                        |
| 06 | Apport interannuel            | 103,00Hm/An                                  |
| 07 | Envasement annuel             | 0.204 hm <sup>3</sup> /An                    |
| 08 | Surface du bassin versant     | 650,00 Km <sup>2</sup>                       |
| 09 | Type                          | Terre (Digue en remblai avec noyau vertical) |
| 10 | Hauteur                       | 71,30m                                       |
| 11 | Longueur                      | 852,42m                                      |
| 12 | Côte retenue Normale (R.N)    | 139, 00m                                     |
| 13 | Côte Plus Hautes Eaux (P.H.E) | 142,20 m                                     |
| 14 | Évacuateur de crue            | déversoir en tranchée                        |
| 15 | Débit d'évacuation            | 1 245 m <sup>3</sup> /s                      |
| 16 | Vidange de Fond               | 55 m <sup>3</sup> /s                         |

#### II.2.4. Barrage Hammam Debagh

Le barrage de Bouhamdane sur l'oued Bou Hamdane est situé dans la commune de Hammam-Debagh, à 20 kilomètres à l'ouest de la ville de Guelma, dans l'est algérien. Il est destiné à la régularisation des apports en vue de satisfaire les besoins pour l'irrigation du périmètre de Guelma-Boucheougouf d'une superficie de 13000 Ha (**Figure II.5**). Les caractéristiques techniques du barrage Bouhamdane sont reportés dans le **Tableau II.4**.

**Tableau II. 4.** Caractéristiques techniques du barrage Hammam Debagh.

|    |                               |                          |
|----|-------------------------------|--------------------------|
| 01 | Année de construction         | <b>1980</b>              |
| 02 | Année de mise en Eau          | <b>1987</b>              |
| 03 | Oued                          | Bouhamdane               |
| 04 | Capacité initiale             | 200,00 hm <sup>3</sup>   |
| 05 | Capacité dernier levé (2004)  | 184,35 hm <sup>3</sup>   |
| 06 | Apport moyen annuel           | 69,0 hm <sup>3</sup>     |
| 07 | Envasement annuel             | 0,53 hm <sup>3</sup> /an |
| 08 | Surface du bassin versant     | 1 070 km <sup>2</sup>    |
| 09 | Type                          | TERRE                    |
| 10 | Hauteur                       | 95 m                     |
| 11 | Longueur                      | 430 m                    |
| 12 | Côte retenue Normale (R.N)    | 360,00 m                 |
| 13 | Côte Plus Hautes Eaux (P.H.E) | 370,24 m                 |
| 14 | Évacuateur de crue            | Corolle et Seuil Libre   |
| 15 | Débit d'évacuation            | 2 240 m <sup>3</sup> /s  |
| 16 | Vidange de Fond               | 218 m <sup>3</sup> /s    |




Figure II. 5. Présentation l'emplacement barrage Hammam Debagh (Guelma).

### II.2.5. Barrage Cheurfas II

Le barrage de Cheurfas est situé à 65 Km au nord de la ville de Mascara, et à 50 Km au Sud-est d'Oran à proximité de la ville de Sig, il a été construit à l'amont de l'ancien barrage de Cheurfas. Il est destiné à l'irrigation des périmètres agricoles de la plaine de SiG (Figure II.6).

Tableau II. 5. Caractéristiques techniques du barrage Cheurfas.

|    |                              |                          |
|----|------------------------------|--------------------------|
| 01 | Année de construction        | <b>1987</b>              |
| 02 | Année de mise en Eau         | <b>1992</b>              |
| 03 | Oued                         | MEBTOUH                  |
| 04 | Capacité initiale            | 83,10 hm <sup>3</sup>    |
| 05 | Capacité dernier levé (2003) | 70,21hm <sup>3</sup>     |
| 06 | Apport moyen annuel          | 57 hm <sup>3</sup> /an   |
| 07 | Envasement annuel            | 0,36 hm <sup>3</sup> /an |
| 08 | Surface du bassin versant    | 4 190 km <sup>2</sup>    |
| 09 | Type                         | Poids-Béton              |
| 10 | Hauteur                      | 82,40 m                  |
| 11 | Longueur                     | 286 m                    |

|    |                               |                         |
|----|-------------------------------|-------------------------|
| 12 | Côte retenue Normale (R.N)    | 225,0 m                 |
| 13 | Côte Plus Hautes Eaux (P.H.E) | 228,00 m                |
| 14 | Évacuateur de crue            | Vannes Segments         |
| 15 | Débit d'évacuation            | 2 388 m <sup>3</sup> /s |
| 16 | Vidange de Fond               | 100 m <sup>3</sup> /s   |

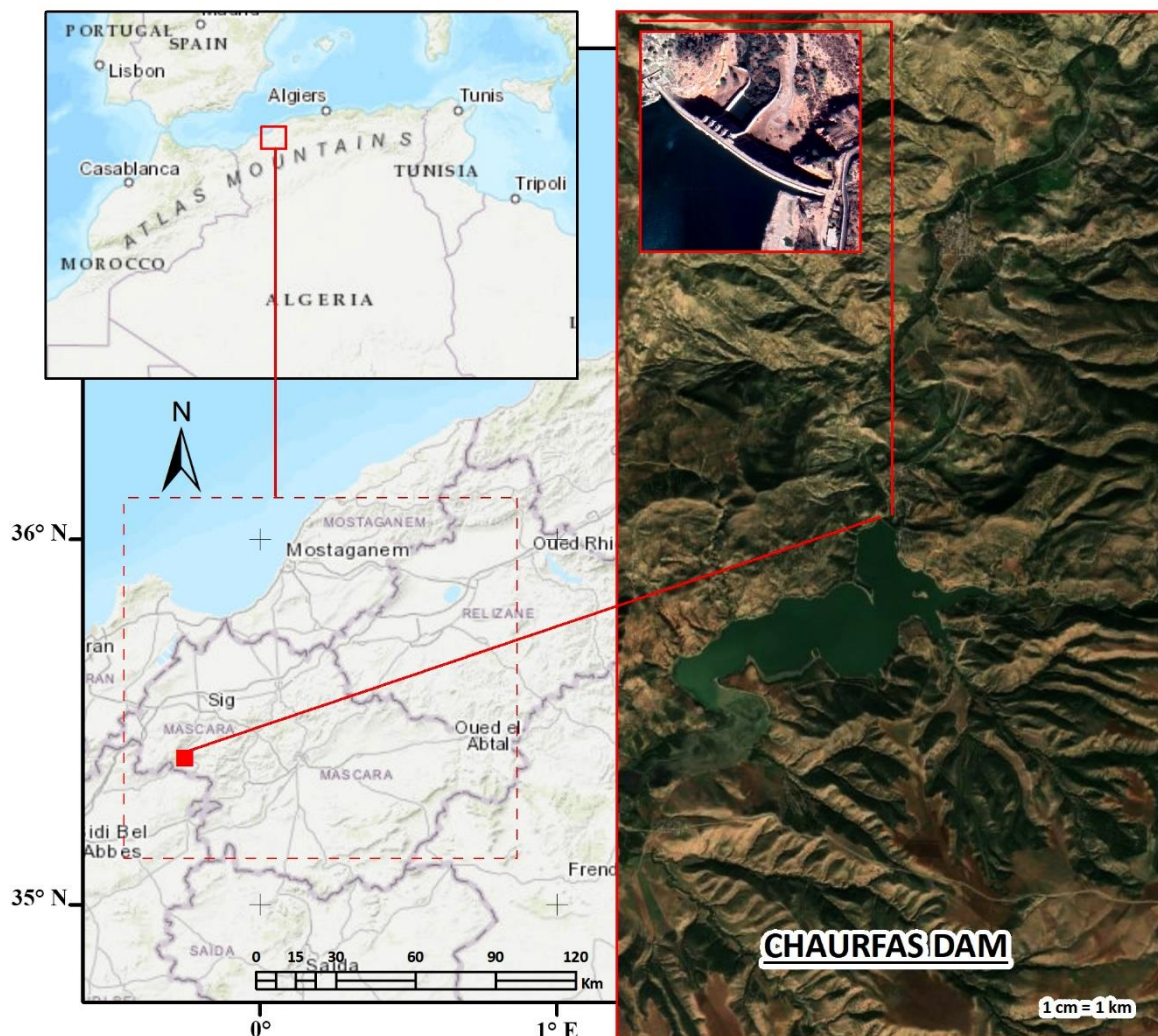


Figure II. 6. Présentations l'emplacement du barrage Chaurfas (Mascara).

### II.3. Présentation et Description de la Base de Données Utilisée

Nous présentons ci-après la description statistique des données utilisées dans la présente étude. En particulier, les relevés piézométrique (PZ), le niveau d'eau du réservoir (CPE), et le débit de fuite ( $Q$ ). Tous les données sont mesurées à pas de temps journaliers (voir **Tableau II.6**). Les mesures sont effectuées au niveau des stations de chaque barrage, avec une variation de la taille de la base de données d'une station à l'autre (**Tableau II.7**).

Tableau II. 6. Statistiques descriptives de la base de données utilisée.

| Variables                  | Unit   | $X_{mean}$ | $X_{max}$ | $X_{min}$ | $S_x$   | $C_v$  | $R$     |
|----------------------------|--------|------------|-----------|-----------|---------|--------|---------|
| <b>Barrage Bougous</b>     |        |            |           |           |         |        |         |
| PZ1                        | m      | 35.25      | 56.37     | 23.12     | 9.346   | 0.265  | 0.519   |
| PZ2                        | m      | 56.39      | 57.75     | 54.32     | 0.745   | 0.013  | 0.478   |
| PZ3                        | m      | 7.61       | 19.79     | 1.50      | 5.001   | 0.657  | 0.523   |
| PZ4                        | m      | 17.77      | 18.64     | 17.06     | 0.393   | 0.022  | 0.094   |
| PZ5                        | m      | 23.58      | 36.75     | 23.02     | 23.380  | 0.992  | 0.012   |
| PZ6                        | m      | 0.07       | 1.17      | 0.00      | 0.257   | 3.683  | 0.015   |
| CPE                        | m      | 135.21     | 232.21    | 122.52    | 7.486   | 0.055  | 0.224   |
| Q                          | L/S    | 31.46      | 64.11     | 0.01      | 16.399  | 0.521  | 1       |
| <b>Barrage Chaurfa</b>     |        |            |           |           |         |        |         |
| PZ1                        | m      | 190.736    | 191.900   | 190.700   | 0.206   | 0.0011 | -0.148  |
| PZ2                        | m      | 173.543    | 177.800   | 156.600   | 5.136   | 0.0296 | 0.303   |
| PZ3                        | m      | 180.146    | 183.500   | 163.090   | 1.939   | 0.0108 | 0.136   |
| PZ4                        | m      | 172.438    | 177.400   | 165.100   | 2.735   | 0.0159 | 0.455   |
| PZ5                        | m      | 180.143    | 187.100   | 166.000   | 3.470   | 0.0193 | 0.574   |
| PZ6                        | m      | 196.818    | 199.050   | 195.050   | 1.964   | 0.0100 | -0.139  |
| CPE                        | m      | 217.248    | 222.370   | 210.070   | 2.774   | 0.0128 | 0.809   |
| Q                          | L/S    | 3.028      | 8.800     | 210.070   | 2.087   | 0.6893 | 1.000   |
| <b>Barrage Zit Emba</b>    |        |            |           |           |         |        |         |
| PZ1                        | m      | 7.606      | 20.400    | 0.000     | 2.663   | 0.350  | -0.601  |
| PZ2                        | m      | 14.505     | 40.320    | 4.640     | 7.014   | 0.484  | -0.693  |
| PZ3                        | m      | 24.892     | 46.610    | 17.410    | 5.698   | 0.229  | -0.562  |
| PZ4                        | m      | 21.138     | 42.900    | 12.990    | 4.312   | 0.204  | -0.729  |
| PZ5                        | m      | 21.216     | 41.310    | 12.680    | 5.184   | 0.244  | -0.613  |
| PZ6                        | m      | 42.906     | 49.320    | 39.760    | 1.884   | 0.044  | -0.637  |
| PZ7                        | m      | 33.049     | 47.810    | 27.520    | 4.422   | 0.134  | -0.731  |
| PZ8                        | m      | 32.432     | 45.360    | 27.500    | 3.220   | 0.099  | -0.713  |
| PZ9                        | m      | 28.484     | 43.400    | 24.630    | 2.393   | 0.084  | -0.541  |
| CPE                        | m      | 81.407     | 86.800    | 61.470    | 6.551   | 0.080  | 0.749   |
| Q                          | L/Min  | 4.125      | 8.700     | 0.000     | 1.611   | 0.391  | 1.000   |
| <b>Barrage Oued Charef</b> |        |            |           |           |         |        |         |
| PZ1                        | m      | 20.139     | 21.810    | 12.790    | 1.626   | 0.0807 | 0.334   |
| PZ2                        | m      | 42.666     | 45.300    | 40.420    | 1.029   | 0.0241 | -0.374  |
| PZ3                        | m      | 43.160     | 45.750    | 34.400    | 2.494   | 0.0578 | 0.264   |
| PZ4                        | m      | 44.995     | 45.690    | 42.120    | 0.519   | 0.0115 | 0.159   |
| PZ5                        | m      | 44.995     | 45.680    | 43.860    | 0.482   | 0.0107 | 0.156   |
| PZ6                        | m      | 44.437     | 45.750    | 35.510    | 1.640   | 0.0369 | 0.157   |
| PZ7                        | m      | 41.064     | 42.960    | 38.160    | 1.077   | 0.0262 | 0.150   |
| PZ8                        | m      | 25.213     | 25.660    | 23.420    | 0.428   | 0.0170 | 0.172   |
| PZ9                        | m      | 42.444     | 45.040    | 29.360    | 1.912   | 0.0450 | 0.224   |
| WL                         | m      | 739.113    | 745.300   | 727.120   | 4.436   | 0.0060 | 0.419   |
| Q                          | L/S    | 0.254      | 0.567     | 0.044     | 0.176   | 0.6940 | 1.000   |
| <b>Barrage Bouhamdane</b>  |        |            |           |           |         |        |         |
| Vol                        | m      | 129.721    | 213.891   | 11.665    | 44.6311 | 0.3441 | -0.3376 |
| CPE                        | m      | 347.431    | 362.200   | 6.136     | 21.1438 | 0.0609 | -0.1467 |
| Q                          | L/Hour | 0.004      | 0.018     | 0.000     | 0.0030  | 0.7975 | 1.000   |

Les paramètres statistiques calculés pour chaque variable comprennent (**Tableau II.6**) :

- La valeur maximale ( $X_{\max}$ ): la borne supérieure de la série, représentant la valeur la plus élevée.
- La valeur moyenne ( $X_{\text{moy}}$ ): obtenue en divisant la somme des valeurs par leur nombre.
- La valeur minimale ( $X_{\min}$ ): la borne inférieure de la série, indiquant la valeur la plus faible.
- L'écart type ( $S_x$ ): une mesure courante de dispersion.
- Le coefficient de corrélation linéaire (R): illustrant la relation entre les niveaux piézométriques, la côte du plan d'eau et le débit de fuite.
- Le coefficient de variation (CV): le rapport de l'écart-type à la moyenne, signalant une plus grande dispersion autour de la moyenne lorsque sa valeur est élevée.

**Tableau II. 7.** Taille de la base de données utilisée.

| N° | Désignation du barrage     | Début      | Fin        | Taille Échantillon | Apprentissage | Validation |
|----|----------------------------|------------|------------|--------------------|---------------|------------|
| 01 | <i>Barrage Bougous</i>     | 16/02/2009 | 30/03/2019 | 252                | 177           | 75         |
| 02 | <i>Barrage Chorfa</i>      | 24/01/2009 | 23/12/2018 | 298                | 209           | 89         |
| 03 | <i>Barrage Zit Emba</i>    | 30/01/2001 | 24/04/2019 | 326                | 229           | 98         |
| 04 | <i>Barrage Oued Charef</i> | 21/01/2002 | 27/03/2019 | 203                | 143           | 60         |
| 05 | <i>Barrage Bouhamdane</i>  | 01/03/1990 | 31/12/2017 | 10168              | 7118          | 3050       |

## II.4. Conclusion

Dans ce chapitre, nous avons entrepris la description et la de la zone d'étude, englobant cinq barrages répartis dans diverses régions du nord de l'Algérie. Ces barrages ont été choisis comme échantillons en vue de contribuer à la compréhension et à la modélisation du phénomène d'infiltration à travers ces structures, en utilisant des techniques d'intelligence artificielle. Nous avons également examiné la base de données spécifique à chaque barrage, procédant à une analyse statistique exhaustive de l'ensemble des données. Cette approche nous a conféré une perspective plus approfondie de la base de données à notre disposition. Les chapitres à venir se pencheront sur les méthodes d'intelligence artificielle que nous adopterons dans le cadre de la modélisation, suivies d'une discussion approfondie de leurs performances.

---

**Chapitre III: Description des Modèles à Base  
d'Intelligences Artificielles**

---

### III.1. Introduction

L'intelligence artificielle (**IA**) est l'un des domaines les plus récents de la science et de l'ingénierie. Le domaine de **IA**, va plus loin encore : il tente non seulement de comprendre mais aussi de construire des entités intelligentes. Les travaux ont commencé sérieusement peu après la seconde guerre mondiale, et le nom lui-même a été inventé en 1956. L'**IA** englobe actuellement une grande variété de sous-domaines, allant du général (apprentissage et perception) au spécifique, comme jouer aux échecs, prouver des théorèmes mathématiques, écrire de la poésie, conduire une voiture dans une rue bondée et diagnostiquer des maladies. Les premiers efforts de l'**IA** consistaient à modéliser les neurones du cerveau. Un neurone artificiel est traité comme une variable binaire qui est activée ou désactivée. Cette notion a été proposée pour la première fois dans (McCulloch & Pitts, 1943), et a été approfondie par (Hebb, 1949) lorsqu'il a développé l'apprentissage hebbien pour les réseaux de neurones. En 1951, Marvin Minsky et Dean Edmonds ont construit le **SNARC**, le premier ordinateur à réseau neuronal. La plupart des premiers succès de l'**IA** reposaient sur la modélisation de la logique humaine. En 1955-1956, Allen Newell et Herbert Simon ont développé un programme appelé Logic Theorist qui visait à imiter les compétences de résolution de problèmes d'un être humain et est considéré comme le premier programme d'**IA**.

### III.2. Réseaux De Neurones Artificiels

La théorie des réseaux neurones artificiels (**ANN**) est basée sur l'analyse d'un système nerveux biologique. Une structure nerveuse biologique se compose de neurones et leurs connexions. Les **ANN** peuvent être décrits comme un groupe d'éléments de traitement simples disposés en couches parallèles qui sont entièrement interconnectées par des connexions pondérées. Un modèle mathématique d'un réseau neurones est créé, basé sur cette structure et la transmission du signal. Ce modèle a été construit à partir d'une entrée, d'une sortie et d'une ou plusieurs couches cachées constituées de neurones (S. Haykin, 1994) . Il existe plusieurs types de réseau ANN et ils peuvent être classés et sous-classes selon divers critères. Un de ces critères (Parlos et al., 1992) classe les **ANN** selon leur modèle de connectivité, leur mode d'apprentissage, leurs applications, leur mode d'exploitation, leur type de données et leur règle d'apprentissage. La forme la plus populaire d'**ANN** utilisée est à propagation vers l'avant (**FeedForward ANN**). Dans cette classe d'**ANN**, les informations circulent uniquement vers l'avant. Parmi les **ANN** à propagation vers l'avant, le perceptron multicouche (**MLPNN**). Les valeurs des couches précédentes sont passées à travers les neurones ( $x_1, x_2, \dots, x_n$ ) qui ont été connectés avec poids ( $w_1, w_2, \dots, w_n$ ) comme suit (**Figure III.1**) :

|  |         |
|--|---------|
| $y = \varphi \left( \sum_{i=1}^n w_i \times x_i + \beta_i \right)$ | (III.1) |
|--|---------|

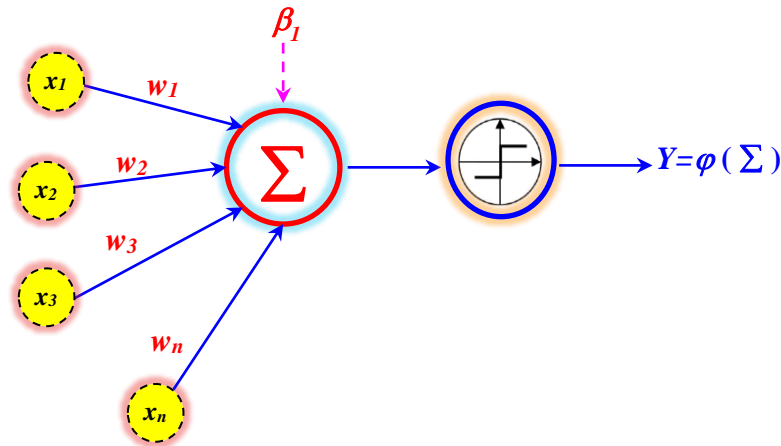
Avec:

$x_i$  : signal d'entrée,

$y$  : signal de sortie des neurones.,

$w_i$  : poids,

$\beta_0$  : biais,  
 $\varphi$  : fonction d'activation.



**Figure III. 1.** Traitement du signal dans un neurone artificiel.

La valeur du résultat de la somme a été transmise à la valeur de sortie du nœud à l'aide d'une fonction d'activation. Plusieurs fonctions sont souvent utilisées en tant que fonctions d'activation dans la couche cachée et la couche de sortie, parmi lesquelles :

- |  |  |
|--|--|
| 1) La fonction identité :              | $f(A) = A$                                 |
| 2) La fonction sigmoïde :              | $f(A) = \frac{1}{1+e^{-A}}$                |
| 3) La fonction Tangente hyperbolique : | $f(A) = \frac{e^A - e^{-A}}{e^A + e^{-A}}$ |

On peut voir d'après ce qui précède pourquoi les ANN sont considérés comme des modèles de boîte noire : simplement, ils relient un certain nombre d'entrées à un certain nombre de sorties correspondantes sans avoir besoin d'un modèle physique décrivant le processus modélisé.

### III.3. Les Perceptrons Multicouches (MLPNN)

Le perceptron multicouche (MLPNN) est le type des réseaux de neurones le plus largement étudié et utilisé (Rumelhart et al., 1986). Un MLPNN typique à au moins trois couches: une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Comme illustré dans la Figure II.2, le MLPNN peut avoir plus d'une couche cachée; cependant, des travaux théoriques ont montré qu'une seule couche cachée est suffisante pour qu'un ANN se rapproche de toute fonction non linéaire complexe (Cybenko, 1989; Hornik et al., 1989). La couche d'entrée (Input Layer) se compose de plusieurs neurones ( $x_i$ ), chacun représente une variable indépendante (Input). Les neurones de la couche d'entrée sont interconnectés avec les neurones de la couche cachée par l'intermédiaire des poids ( $W_{ij}$ ). La couche cachée se compose de plusieurs neurones à déterminer par expérience (Trial and errors). Les neurones de la couche cachée sont interconnectés avec les neurones de la couche de sortie par l'intermédiaire des poids ( $W_{jk}$ ). Les neurones de la couche cachée et de la couche de sortie possèdent des biais ( $\beta_j$ ).

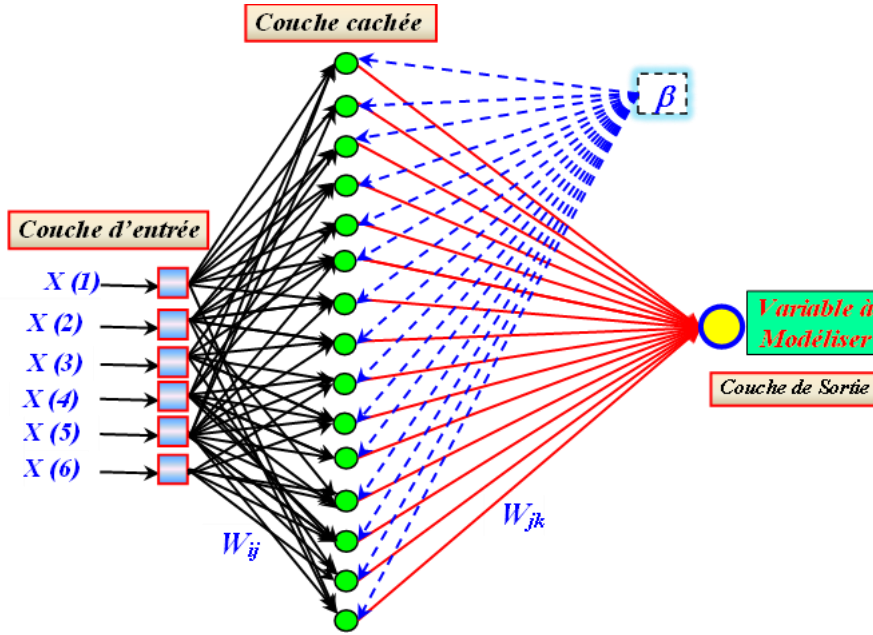


Figure III. 2. Schéma détaillé d'un perceptron multicouche (MLPNN).

L'apprentissage des modèles MLPNN est réalisé par la technique de Levenberg-Marquardt car cette technique est plus puissante que les techniques classiques de descente de gradient (Cigizoglu & Kişi, 2005; El-Bakry, 2003; Hagan & Menhaj, 1994). Le MLPNN transforme  $n$  entrées en  $m$  sorties via une fonction non linéaire. Les poids du MLPNN sont entraînés par l'algorithme de rétropropagation (Park et al., 2002). L'apprentissage du réseau MLPNN est une étape importante pour obtenir les valeurs optimales des poids et de biais après avoir été initialisé de manière aléatoire. Les processus d'apprentissage nécessitent un ensemble de prototypes et de cibles pour apprendre le comportement correct du réseau. Pendant la phase d'apprentissage, les poids et les biais du réseau sont ajustés de manière itérative pour minimiser la fonction de performance du réseau qui est l'erreur quadratique moyenne calculée entre les entrées et les cibles (Lera & Pinzolas, 1998). Un neurone d'un perceptron multicouche se caractérise par trois concepts : son état, ses connexions avec d'autres neurones, et sa fonction d'activation.

$$A_j = b_j + \sum_{i=1}^n W_{ij} \times x_i \quad (\text{III.2})$$

$$O_k = b_k + \sum_{j=1}^m W_{jk} \times f_i(A_j) \quad (\text{III.3})$$

Avec :

$x_i$  : l'entrée  $i$ ;

$A_j$  : Etat du neurone  $j$  de la couche cachée (égale à la somme pondérée de toutes les entrées  $x_i$  plus un biais);

$W_{ij}$  : Poids de la connexion entre les neurones de la couche d'entrée et la couche cachée ;

$W_{jk}$  : Poids de la connexion entre les neurones de la couche de sortie et la couche cachée

$f$ : Fonction d'activation du neurone  $j$  appartenant à la couche cachée (la sigmoïde);

$\beta_j$  : le biais associé au neurone  $j$  de la couche cachée;

$\beta_k$  : le biais associé au neurone  $k$  de la couche de sortie;

$n$  : nombre de neurone dans la couche d'entrée;

$m$  : nombre de neurone dans la couche cachée;

$p$  : nombre de neurone dans la couche de sortie;

$O_k$ : Etat du neurone  $k$  de la couche de sortie.

### III.3.1. L'Algorithme de Rétropropagation du Gradient (BP)

L'algorithme de rétropropagation du Gradient (**BP**) est l'un des algorithmes d'apprentissage les plus populaires dans les réseaux de neurones. Cet algorithme effectue une approximation de la minimisation globale obtenue par la méthode de descente la plus raide. L'algorithme peut être considéré comme une généralisation de l'algorithme adaptatif des moindres carrés moyens (**LMS**).

$$x_i^{(l+1)} = f \left( \sum_{j=l}^N w_{ij}^{(l)} x_j^{(l)} + \theta_j^{(l)} \right) \quad (\text{III.4})$$

Le signal d'erreur  $\epsilon_j$  nécessaire à l'adaptation est défini comme la différence entre la réponse souhaitée et la sortie du perceptron:

$$\epsilon_j(n) = d_j(n) - y_j(n), j = 1, 2, \dots, N_M \quad (\text{III.5})$$

Où  $d_j(n)$  est la réponse souhaitée au  $j^{\text{ième}}$  nœud de la couche de sortie à l'instant  $n$ ;  $y_j(n)$  est la sortie au  $j^{\text{ième}}$  nœud de la couche de sortie, et  $N_M$  est le nombre de nœuds dans la  $M^{\text{ième}}$  couche de sortie. Par conséquent, la somme des carrés d'erreur produits par le réseau est:

$$E(n) = \sum_{j=1}^{N_M} \epsilon_j(n) \epsilon_j^*(n) \quad (\text{III.6})$$

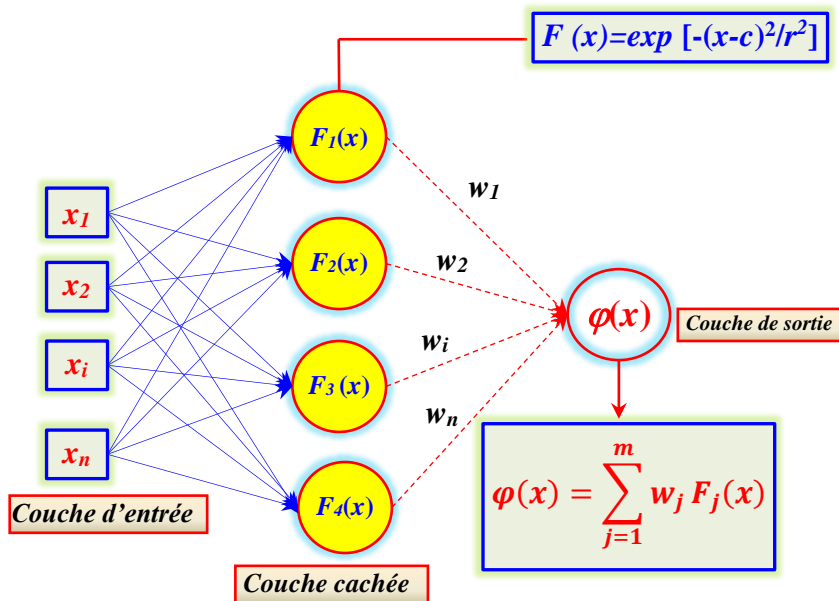
L'algorithme **BP** minimise la fonction de coût  $E(n)$  en modifiant de manière récursive les paramètres  $\{W_{ij}^{(l)}, \beta_i^{(l)}\}$  basé sur la technique de recherche de gradient. Ainsi, trouver le vecteur gradient de  $E(n)$  est l'idée principale de la dérivation de l'algorithme **BP**. Nous trouvons d'abord la dérivée partielle de  $E(n)$  par rapport aux coefficients de la couche de sortie, puis nous étendons au coefficient de toutes les unités cachées. Puisque  $E(n)$  est une fonction à valeur réelle qui n'est pas analytique, nous devons dériver séparément la dérivée partielle de  $E(n)$  par rapport à la partie réelle et imaginaire des coefficients.

### III.4. Les Réseaux de Neurones à Fonction de Base Radiales (RBFNN)

Parmi plusieurs architectures possibles des **ANN**, l'une des plus efficaces et des plus économiques en termes de calcul est le type de fonctions de base radiales (**RBFNN**). Le réseau de neurones **RBFNN** est un réseau de neurones proposé par (Broomhead & Lowe, 1988; Moody

& Darken, 1989; Sun et al., 2011). Comme le montre la **Figure III.3**, l'interprétation de la méthode **RBNN** en tant que réseau neuronal artificiel se compose de trois couches: une couche de neurones d'entrée alimentant les vecteurs de caractéristiques dans le réseau; une couche cachée de neurones **RBNN** calculant le résultat des fonctions de base; et une couche de neurones de sortie, calculant une combinaison linéaire des fonctions de base (Taurino et al., 2003).

Dont les neurones utilisent des fonctions de base radiales, tandis que dans la couche de sortie, la fonction linéaire est adoptée (Broomhead & Lowe, 1988). Le fait que le mappage de l'entrée à la sortie soit non linéaire et que le mappage de l'espace de la couche cachée à l'espace de sortie soit linéaire peut considérablement accélérer le processus d'apprentissage et éviter les minima locaux et peut également approximer toute fonction continue avec une précision arbitraire (Sun et al., 2011). Cependant, il est difficile de déterminer des paramètres tels que les poids de connexion, les largeurs de centre et les valeurs centrales pour la fonction gaussienne (X. Chen et al., 2020). Le modèle **RBFNN** est motivé par la réponse localement accordée observée dans les neurones biologiques. Les neurones avec une caractéristique de réponse localement accordée peuvent être trouvés dans plusieurs parties du système nerveux, par exemple, les cellules du cortex visuel sensibles aux barres orientées dans une certaine direction ou d'autres caractéristiques visuelles dans une petite région du champ visuel (Poggio & Girosi, 1990). Ces neurones accordés localement présentent des caractéristiques de réponse limitées par une petite plage de l'espace d'entrée.



**Figure III. 3.** Architecture Détaillé des Réseaux de Neurones RBFNN.

Notons qu'à la couche d'entrée il y a  $N$  nœuds, à la couche intermédiaire il y a  $N_1$  neurones et à la couche de sortie il y a  $N_2$  neurones. Habituellement, le nombre de nœuds d'entrée et le nombre de neurones de sortie sont préalablement établis pour l'application considérée, de sorte qu'il reste à étudier le nombre de neurones dans la couche intermédiaire et tous les autres paramètres ANN. Il est possible de déterminer le nombre de neurones de la couche intermédiaire comme étant égal au nombre de motifs d'entrée. Ainsi, le réseau mappe avec précision tous les vecteurs d'entrée avec les sorties souhaitées. Cependant, cette

cartographie exacte n'est pas souhaitable car elle conduit généralement à un surajustement et cette méthode n'a pas été adoptée. D'autre part, une très petite quantité n'est pas non plus très souhaitable car le réseau passerait beaucoup de temps à essayer de trouver la meilleure représentation du problème physique. Différents algorithmes D'apprentissage peuvent être utilisés pour ajuster les paramètres (poids, centres, largeurs) des réseaux **RBFNN**. La plupart de ces méthodes comportent deux phases. Dans la première phase, le nombre de fonctions radiales et leurs paramètres sont déterminés. Ces paramètres sont ajustés par des algorithmes non supervisés (Moody & Darken, 1989), tandis que dans la deuxième phase les poids des neurones de sortie sont ajustés. Le temps d'apprentissage d'un réseau **RBFNN** est généralement plus rapide que celui des autres types de réseaux, puisque les méthodes d'apprentissage pour ajuster les fonctions radiales et les poids synaptiques peuvent être enchaînées séquentiellement (Mulgrew, 1996), permettant un apprentissage optimisé.

Les paramètres RBFNN ont été calculés comme suit (S. Chen et al., 1992): d'abord les centres sont obtenus à l'aide de l'algorithme Kmeans non supervisé (Moody & Darken, 1989). Une fois les centres calculés, les largeurs sont déterminées. Enfin, après avoir défini les paramètres des fonctions radiales, les paramètres libres de la couche de sortie sont calculés en utilisant les mêmes procédures que celles utilisées pour la couche de sortie des autres types de réseaux de neurones (S. S. Haykin, 2009). Dans la première phase de la formation RBFNN, l'algorithme Kmeans qui est une technique de clustering qui partitionne l'ensemble des modèles d'entrée en  $N_1$  ensembles disjoints  $S_j$  contenant  $K_j$  vecteurs. Après cette étape, les centres  $\mu_j$  sont recalculés par la moyenne des vecteurs appartenant à l'ensemble, sous la forme

$$\mu_j = \frac{1}{k_j} \sum_{x(p) \in S_j} x(p) \quad (\text{III.7})$$

Cette mise à jour des centres et des vecteurs associés au centre le plus proche se fait jusqu'à la convergence de l'algorithme, c'est-à-dire lorsque les centres n'ont plus besoin d'être changés. Avec les centres déjà calculés, la largeur de chaque fonction radiale  $\sigma_j$  est déterminée par la moyenne sur toutes les distances euclidiennes entre le centre de l'ensemble  $S_i$  et le centre de  $S_j$ , c'est-à-dire

$$\sigma_j = \frac{1}{N_1} \sum_{i=1}^{N_1} \|\mu_j - \mu_i\| \quad (\text{III.8})$$

Dans la deuxième phase de la formation **RBFNN**, la tâche consiste à calculer les poids synaptiques et le biais des neurones de la couche de sortie. Contrairement à la première phase de la formation **RBFNN**, la deuxième phase utilise une procédure d'apprentissage supervisé (Moody & Darken, 1989). Dans cette phase, les principales étapes sont :

1. Initialiser les paramètres libres des neurones de la couche de sortie;
2. Spécifiez la précision requise et le nombre maximum d'itérations;
3. Présenter au réseau le vecteur  $x(p)$  appartenant à l'ensemble d'apprentissage
4. Calculez la sortie réseau;

5. Lorsque tous les vecteurs de l'ensemble d'apprentissage ont été présentés, déterminez l'erreur quadratique moyenne;
6. Si l'erreur moyenne quadratique est inférieure à la précision requise ou si le nombre d'itérations est supérieur à une valeur maximale, alors mémoriser les paramètres libres du réseau. Sinon, retournez à l'étape 3.

### III.5. Réseaux de Neurones de Régression Généralisée (GRNN)

Le réseau de neurones de Régression Généralisée (Generalized Regression Neural Network: **GRNN**) a été initialement proposé par (Specht, 1991). Il appartient à la catégorie des réseaux de neurones probabilistes. En raison de sa forte capacité d'approximation non linéaire et de sa vitesse d'apprentissage, le **GRNN** peut approximer n'importe quelle fonction ou relation non linéaire. Le schéma du **GRNN** est illustré à la **Figure III.4**.

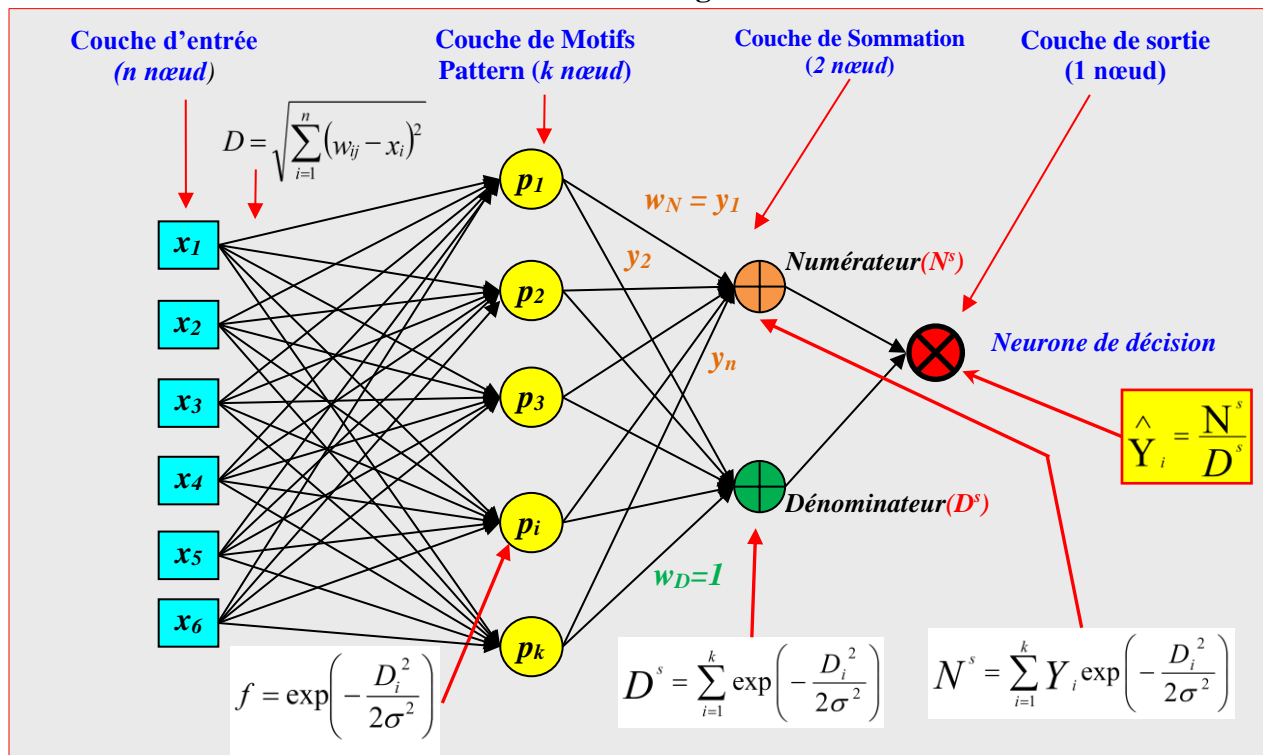


Figure III.4 . Schéma général du réseau de neurones GRNN (Heddam, 2017).

Les bases du **GRNN** sont données dans (Specht, 1991) et (Tsoukalas & Uhrig, 1996). Le **GRNN** se compose de quatre couches: couche d'entrée, couche de motifs, couche de sommation et couche de sortie. Le nombre d'unités d'entrée dans la première couche est égal au nombre total de variables indépendante. La première couche est entièrement connectée à la seconde couche de motifs, où chaque unité représente un motif d'apprentissage et sa sortie est une mesure de la distance entre l'entrée et les motifs stockés. Chaque unité de couche de motif est connectée à deux neurones dans la couche de sommation: le numérateur ( $N^s$ ) et le dénominateur ( $D^s$ ). Le numérateur ( $N^s$ ) calcule la somme des sorties pondérées de la couche de motif tandis que le dénominateur ( $D^s$ ) calcule les sorties non pondérées des neurones de motif. Le poids de connexion entre le  $i^{\text{ème}}$  neurone dans la couche de motif et le neurone de sommation

est  $y_i$  ; la valeur de sortie cible correspondant au  $i^{\text{ème}}$  modèle d'entrée. Pour le neurone  $D^s$ , le poids de la connexion est égal à l'unité. La couche de sortie divise simplement la sortie de chaque neurone  $N^s$  par celle de chaque neurone  $D^s$ .

La méthode **GRNN** ne nécessite pas une procédure d'apprentissage itérative comme dans **MLPNN**. Le **GRNN** est utilisé pour l'estimation des variables continues, comme dans les techniques de régression standard. Il est lié au réseau **RBFNN** et repose sur une technique statistique standard appelée régression par noyau ([Specht, 1991](#)). La fonction de densité de probabilité conjointe (*pdf*) de  $x$  et  $y$  est estimée au cours d'un processus d'apprentissage dans le **GRNN**. Parce que le *pdf* est dérivé des données de formation sans aucune idée préconçue sur sa forme, le système est parfaitement général. Le succès du **GRNN** dépend fortement des facteurs de propagation ([Specht, 1991](#); [Wasserman, 1993](#)): plus la propagation est grande, plus l'approximation de la fonction est fluide. Une propagation trop importante signifie qu'un grand nombre de neurones seront nécessaires pour s'adapter à une fonction qui évolue rapidement. Une propagation trop petite signifie que de nombreux neurones seront nécessaires pour s'adapter à une fonction fluide, et le réseau peut ne pas bien se généraliser.

Supposons que  $f(x, y)$  représente la fonction de densité de probabilité continue conjointe connue d'une variable aléatoire vectorielle,  $x$ , et d'une variable aléatoire scalaire  $y$ . Soit  $X$  une valeur mesurée particulière de la variable aléatoire  $x$ . La moyenne conditionnelle de  $y$  étant donné  $X$  (également appelée la régression de  $y$  sur  $X$ ) est donnée par:

$$E[y|X] = \frac{\int_{-\infty}^{\infty} y f(X, y) dy}{\int_{-\infty}^{\infty} f(X, y) dy} \quad (\text{III.9})$$

Lorsque la densité  $f(x, y)$  n'est pas connue, elle doit généralement être estimée à partir d'un échantillon d'observations de  $x$  et  $y$ . Pour une estimation non paramétrique de  $(x, y)$ . L'estimateur de probabilité  $f(x, y)$  est basé sur des valeurs d'échantillon  $X^i$  et  $Y^i$  des variables aléatoires  $x$  et  $y$ , où  $n$  est le nombre d'observations de l'échantillon et  $p$  est la dimension de la variable vectorielle  $x$ :

$$\hat{f}(X, Y) = \frac{1}{(2\pi)^{(p+1)/2} \sigma^{(p+1)}} \cdot \frac{1}{n} \sum_{i=1}^n \exp \left[ -\frac{(X - X^i)^T (X - X^i)}{2\sigma^2} \right] \cdot \exp \left[ -\frac{(Y - Y^i)^2}{2\sigma^2} \right] \quad (\text{III.10})$$

Une interprétation physique de l'estimation de probabilité  $f(X, Y)$  est qu'elle attribue une probabilité d'échantillon de largeur  $\sigma$  pour chaque échantillon  $X^i$  et  $Y^i$ , et l'estimation de probabilité est la somme de ces probabilités d'échantillonnage. Substitution de la probabilité conjointe estimer  $f$  dans la moyenne conditionnelle à la moyenne conditionnelle souhaitée de  $y$  étant donné  $X$ . En particulier, on aura par combinaison des équations précédentes :

$$\hat{Y}(X) = \frac{\sum_{i=1}^n \exp \left[ -\frac{(X - X^i)^T (X - X^i)}{2\sigma^2} \right] \int_{-\infty}^{\infty} y \exp \left[ -\frac{(y - Y^i)^2}{2\sigma^2} \right] dy}{\sum_{i=1}^n \exp \left[ -\frac{(X - X^i)^T (X - X^i)}{2\sigma^2} \right] \int_{-\infty}^{\infty} \exp \left[ -\frac{(y - Y^i)^2}{2\sigma^2} \right] dy} \quad (\text{III.11})$$

Finalement on aura :

$$N^S = \sum_{i=1}^n Y^i \exp \left[ -\frac{D_i^2}{2\sigma^2} \right] \quad (\text{III.12})$$

$$D^S = \sum_{i=1}^n \exp \left[ -\frac{D_i^2}{2\sigma^2} \right] \quad (\text{III.13})$$

$$Y(X) = \frac{N^S}{D^S} = \frac{\sum_{i=1}^n Y^i \exp \left[ -\frac{D_i^2}{2\sigma^2} \right]}{\sum_{i=1}^n \exp \left[ -\frac{D_i^2}{2\sigma^2} \right]}, \quad (\text{III.14})$$

Étant donné que l'estimateur particulier se décompose facilement en facteurs  $x$  et  $y$ , les intégrations ont été effectuées analytiquement. La régression résultante qui implique des sommations sur les observations, est directement applicable aux problèmes impliquant des données numériques.

### III.6. Système d'Inférence Flou à base de Réseaux de Neurones Adaptatifs (ANFIS) :

Le système d'inférence flou à base de réseaux de neurones adaptatifs (ANFIS) a été introduit par Jang (Jang, 1993). Selon Jang, l'ANFIS est un réseau de neurones fonctionnellement identique à un modèle d'inférence de type Takagi-Sugeno. ANFIS est devenu une technique de modélisation attractive et puissante, combinant des lois d'apprentissage bien établies des ANN et la transparence linguistique de la théorie de la logique floue dans le cadre des réseaux adaptatifs. Les systèmes d'inférence floue (FIS) sont l'une des applications les plus connues de la théorie de la logique floue. Dans les systèmes d'inférence floue, les fonctions d'appartenance doivent généralement être ajustées manuellement par essais et erreurs. Le modèle FIS fonctionne comme une boîte blanche, ce qui signifie que les concepteurs du modèle peuvent découvrir comment le modèle a atteint son objectif. D'un autre côté, les réseaux de neurones artificiels (ANN) peuvent apprendre, mais fonctionnent comme une boîte noire en ce qui concerne la manière dont l'objectif est atteint.

L'application de la technique ANN pour optimiser les paramètres d'un modèle flou nous permet d'apprendre à partir d'un ensemble donné de données d'apprentissage, tout comme un ANN. Dans le même temps, Les solutions sur un système d'inférence floue (FIS) peuvent donc être décrites dans des étiquettes linguistiques (ensembles flous) (Melin et al., 2012). Ainsi, les

nœuds et les couches cachées sont déterminés précisément par un FIS dans le modèle ANFIS. L'ANFIS ne nécessite pas de modèle mathématique complexe, il est rapide et adaptatif et l'outil de prédiction développé peut être mis en œuvre rapidement.

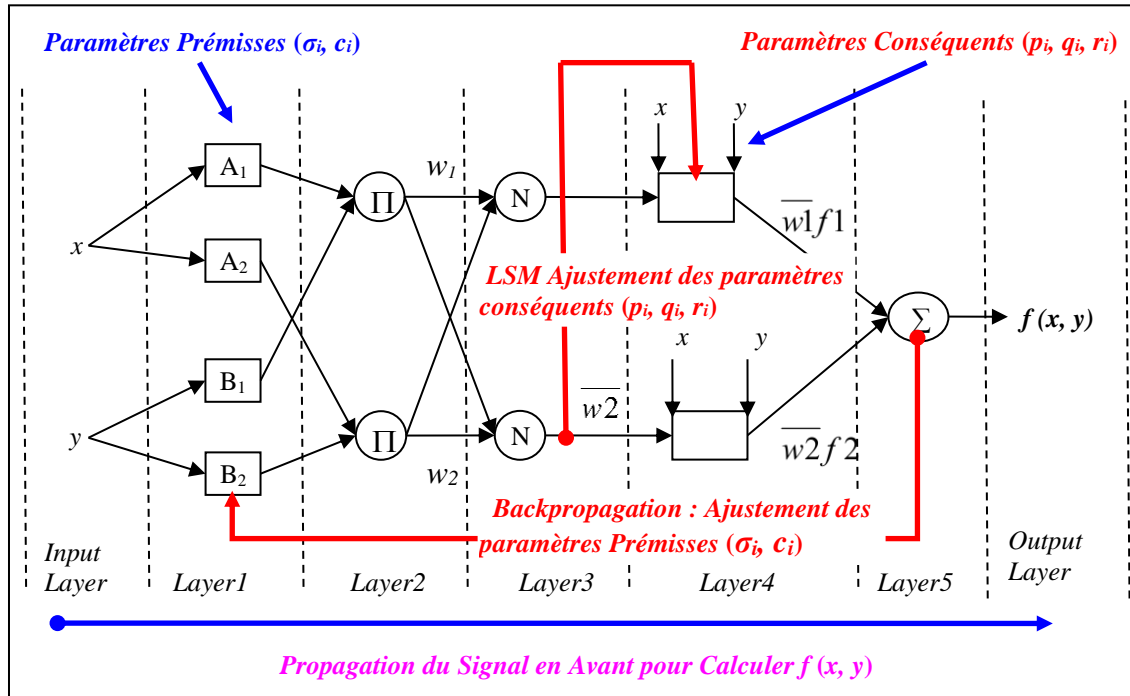


Figure III. 5. Système d'Inférence Flou à base de Réseaux de Neurones Adaptatifs (ANFIS).

L'architecture d'ANFIS est illustrée sur la Figure III.5. Cinq couches sont utilisées pour construire ce modèle. Chaque couche contient plusieurs nœuds décrits par la fonction de nœud. Les nœuds adaptatifs, désignés par des carrés, représentent les ensembles de paramètres qui sont ajustables dans ces nœuds. Inversement, les nœuds fixes, indiqués par des cercles, représentent les ensembles de paramètres qui sont fixes dans le modèle. Une architecture ANFIS simple, qui utilise deux variables ( $T_1$  et  $T_2$ ) en entrées et une sortie ( $F$ ), sera décrite dans cette section afin d'expliquer le concept de la structure ANFIS.

- **Couche 1:** La première couche est la couche floue qui convertit les entrées en sous-ensemble flou au moyen de fonctions d'appartenance (MF). Il contient des nœuds adaptatifs avec des fonctions de nœud décrites comme :

$$O_{1,i} = \mu_{A_i}(T_1), \quad \text{for } i = 1,2 \quad (\text{III.15})$$

$$O_{1,i} = \mu_{B_{i-2}}(T_2), \quad \text{for } i = 3,4 \quad (\text{III.16})$$

où  $T_1$  et  $T_2$  sont le nœud d'entrée  $i$ , A et B sont les étiquettes linguistiques associées à ce nœud (sous ensemble flou),  $\mu(T_1)$  et  $\mu(T_2)$  sont les fonctions d'appartenance (MF), Il existe de nombreux types de MF qui peuvent être utilisés. Cependant, une fonction de forme gaussienne avec un maximum et un minimum égaux à 1 et 0 est généralement adaptée. Les paramètres de cette couche sont définis comme des paramètres de prémisses.

- **Couche 2 :** Chaque nœud de cette couche est un nœud fixe, marqué par un cercle et étiqueté par  $\Pi$ , avec la fonction de nœud à multiplier par les signaux d'entrée pour servir de signal de sortie. Cette couche sert à calculer le degré d'activation des prémisses

$$O_{2,i} = W_i = \mu_{A_i}(T_1) \cdot \mu_{B_{i-2}}(T_2), \quad for \ i = 1,2 \quad (III.17)$$

Où  $O_{2,i}$  est la sortie de la couche 2. Le signal de sortie  $w_i$  représente la force de la règle.

- **Couche 3:** Chaque nœud de cette couche est considéré comme un nœud fixe, marqué par un cercle et étiqueté par  $N$ , avec une fonction de nœud pour normaliser la force de tir en calculant le rapport entre la force du  $i^{ième}$  nœud et la somme de la force de toutes les règles. Cette opération est appelée la normalisation des poids.

$$O_{3,i} = \bar{w} = \frac{w_i}{w_1 + w_2}, \quad for \ i = 1,2 \quad (III.18)$$

Où le  $O_{3,i}$  est la sortie de la couche 3. La quantité  $\bar{w}$  est connue sous le nom de force de normalisation .

- **Couche 4:** chaque nœud de cette couche est un nœud ajustable, marqué par un carré, avec la fonction de nœud suivante :

$$O_{4,i} = \bar{w}_i \cdot f_i, \quad for \ i = 1,2 \quad (III.19)$$

Où  $f_1$  et  $f_2$  sont les règles floues si-alors comme suit:

- Règle 1. Si  $T_1$  est  $A_1$  et  $T_2$  est  $B_1$ , Alors  $f_1 = p_1 T_1 + q_1 T_2 + r_1$
- Règle 2. Si  $T_1$  est  $A_2$  et  $T_2$  est  $B_2$ , Alors  $f_2 = p_2 T_1 + q_2 T_2 + r_2$

Où  $p_i$ ,  $q_i$  et  $r_i$  sont les paramètres fixés, appelés paramètres conséquents (paramètres des règles floues)

- **Couche 5:** chaque nœud de cette : couche est un nœud fixe, marqué également par un cercle et étiqueté par  $\Sigma$ , avec une fonction de nœud pour calculer la sortie globale par:

$$O_{5,i} = \sum_i \bar{w}_i \cdot f_i = \frac{\sum_i w_i f_i}{w_i} = f_{out} = Overall \ output \quad (III.20)$$

La règle d'apprentissage la plus simple d'ANFIS est la "Rétropropagation". Cette méthode est appliquée pour identifier les paramètres dans un réseau ANFIS (Jang, 1993).

### III.6.1. Optimization des Règles Floue du Modèle ANFIS

Chaque modèle ANFIS peut être examiné sous deux points de vue : la configuration et l'apprentissage. Le nombre et le type de fonctions d'appartenance et la division des données en différentes règles sont placés dans la classe de configuration, alors que le calcul des

coefficients du modèle (linéaire (les conséquents) et non linéaire (les prémisses)) appartient au processus d'apprentissage. L'une des fonctionnalités de configuration les plus critiques d'un modèle **ANFIS** est le nombre de règles floues si-alors. Trop de règles conduisent à une complexité excessive du système. En revanche, peu de règles conduisent à une description inappropriée du problème. Par conséquent, pour organiser le nombre de règles, les données d'entrée-sortie sont divisées en différentes catégories par des méthodes de regroupement afin qu'une règle floue spécifique soit utilisée pour chaque catégorie et contribue à faciliter le processus d'apprentissage. Pour la modélisation avec le modèle **ANFIS**, le logiciel Matlab propose trois types de systèmes d'inférence floue basés sur Sugeno, et qui sont largement utilisées en modélisation des systèmes entrée-sortie et qui incluent:

1. Le partitionnement en grille dite '*Grid Partitioning (GP)*'
2. Le clustering Soustractif '*Subtractive Clustering (SC)*'
3. Les moyennes C-Floues '*Fuzzy c-means (FCM)*'

La méthode de partitionnement en grille est utilisée avec la commande **GENFIS1** sous Matlab, Le clustering Soustractif est utilisée avec la commande **GENFIS2** sous Matlab, alors que Les moyennes C-Floues sont utilisées avec la commande **GENFIS3** sous Matlab. La première méthode (**GENFIS1**) est utilisée uniquement pour les modèles ayant un nombre d'entrée assez faible pour éviter d'optimiser un modèle **ANFIS** avec un très grand nombre de paramètres. Par exemple, si j'ai six input variables, chacune est divisée en trois sous ensemble flou, on aura  $3^6=729$  règles floues à optimiser. Pour chaque règle floue on aura 7 paramètres linéaires, donc on total on aura  $7 \times 729=5103$  paramètres à optimiser, en plus des paramètres non linéaires qui sont de l'ordre de  $3 \times 6 \times 2=36$  paramètres, ce qui est très difficile à optimiser et l'apprentissage du modèle consomme énormément de temps. Pour cela, dans la présente étude, nous n'avons pas utilisé la méthode (**GP**), et nous avons utilisé uniquement les deux autres techniques: **SC** et **FCM**, qui nécessitent peu de paramètres à optimiser.

### III.7. Machine à Vecteurs de Support des Moindres Carrées (LSSVM)

L'algorithme original de la machine à vecteurs de support (**SVM**) a été introduit par (Vapnik, 1995) sur la base de la théorie de l'apprentissage statistique. Le **SVM** utilise la programmation quadratique afin de formuler le processus de formation de la procédure de modélisation. (Suykens & Vandewalle, 1999) ont proposé une nouvelle **SVM** connue sous le nom machine à vecteurs de support des moindres carrés (*Least square support vector machine* : **LS-SVM**), est proposée pour surmonter les inconvénients (par exemple, le coût de calcul (Anthony & Bartlett, 1999), incertitudes dans la détermination des paramètres structuraux (Arbib, 2003) de **SVM**. Les modèles **LSSVM** résolvent une équation matricielle linéaire avec moins de conditions de contrainte et ont été utilisés dans une variété d'applications, par exemple, la prévision des fluctuations du niveau des eaux souterraines (Aronszajn, 1950), le niveau de la rivière (Baker & Taylor, 1979) et le ruissellement des bassins versants (Bartlett & Mendelson, 2001). Considérons un ensemble d'apprentissage composé de  $M$  données, avec des données d'entrée  $x_t \in R^M$ , et une sortie  $f(x) \in R$  ( $R^M$ ) est l'espace vectoriel  $M$ -dimensionnel et  $R$  est l'espace vectoriel unidimensionnel. Dans l'espace des fonctionnalités, les modèles basés

sur **LSSVM** pour les problèmes de régression peuvent être définis comme (Samui & Kothari, 2011):

$$f(x) = w^t \varphi(x) + b \quad (III.21)$$

Où  $\varphi(\cdot)$  désigne les fonctions de mappage qui transfèrent les données d'entrée dans un espace de caractéristiques de dimension supérieure ;  $w$  est un vecteur de poids ajustable et  $b$  représente le seuil scalaire également appelé biais.

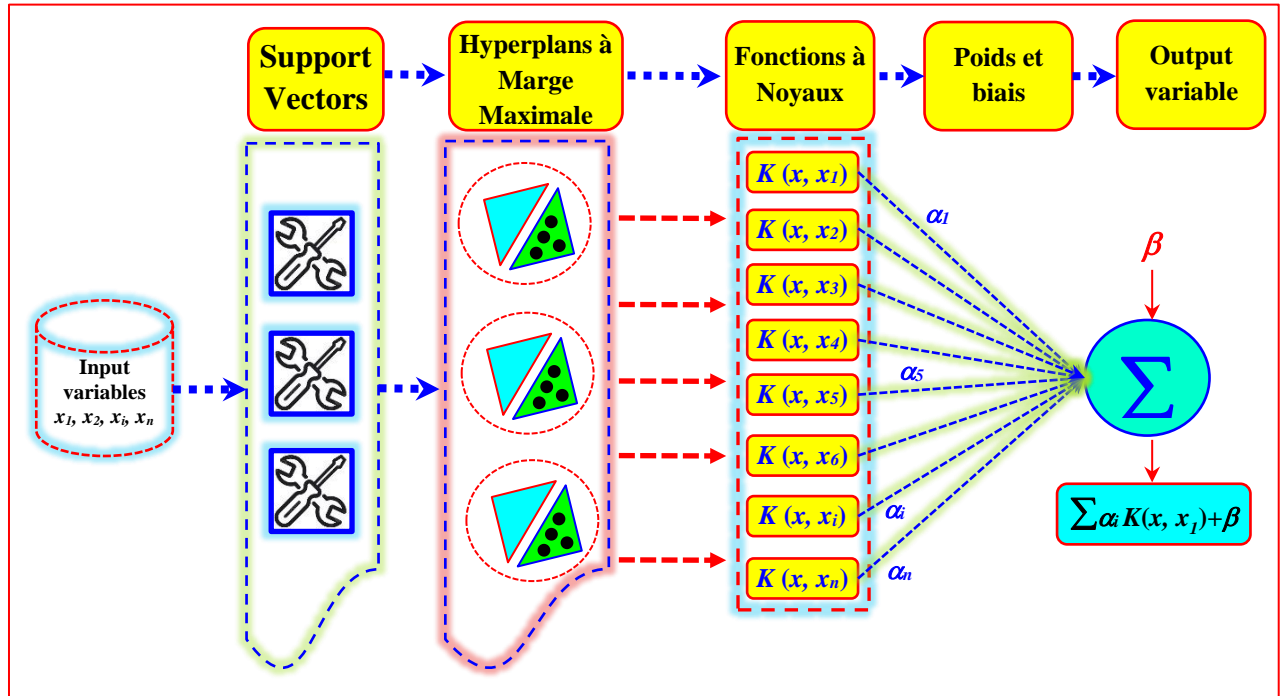


Figure III. 6. L'architecture détaillée du modèle LSSVM.

Le problème d'optimisation suivant peut-être formulé pour l'estimation de fonction:

$$\text{Réduire : } \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{t=1}^M e_t^2 \quad (III.22)$$

$$\text{Soumis à: } f(x) = w^T \varphi(x) + b + e_t, t = 1, \dots, M \quad (III.23)$$

Où  $e$  est l'erreur et  $\gamma$  est la constante de régulation. La forme finale du LSSVM est obtenue en résolvant le problème d'optimisation ci-dessus.

$$f(x) = \sum_{t=1}^M \alpha_t K(x, x_t) + b \quad (III.24)$$

$K(x, x_i)$  est appelée fonction noyau. La fonction du noyau **RBF** a été utilisée dans cette étude à la suite de l'étude précédente (Baensens et al., 2000) dans laquelle les noyaux **RBF** et polynomiaux ont été comparés à l'aide de différents ensembles de données et le premier noyau s'est avéré meilleur que le dernier. La formulation du noyau **RBF** est :

$$K(x, x_t) = \exp\left(-\frac{x - x_t^2}{2\sigma^2}\right) \quad (\text{III.25})$$

### III.8. Régression Multivariée par Spline Adaptative (MARS)

La méthode des Courbe de régression adaptative multivariée (*Multivariate adaptive regression Spline (MARS)*) a été proposée comme méthode non linéaire et non paramétrique pour prédire/prévoir un paramètre dépendant continu (Friedman, 1991). Dans le modèle basé sur **MARS**, des fonctions de base par morceaux sont utilisées pour définir des relations non linéaires complexes entre le paramètre continu et les paramètres vectoriels d'entrée (ensemble de prédicteurs). Ce processus se fait en prenant une procédure avant-arrière (Kisi & Parmar, 2016). Dans l'étape progressive vers l'avant, un grand nombre de fonctions de base (**BF**) sont ajoutées au modèle, ce qui rend le modèle sur-ajuster les données initialement. Les **BF** du modèle basé sur **MARS** dépendent d'une fonction de segment (Spline) qui divise l'ensemble de données en segments linéaires séparés par morceaux. Les fonctions splines sont reliées par des nœuds (point fixe), puis régresse le modèle non linéaire par des fonctions linéaires. La procédure **MARS** est divisée en trois étapes. En général, le modèle basé sur **MARS** peut être décrit comme la structure suivante. Tout d'abord, un algorithme direct sélectionne toutes les fonctions de base possibles et leurs nœuds correspondants. Les fonctions de base représentent la relation entre les variables prédictives ( $x$ ) et la variable cible ( $y$ ) (Adoko et al., 2013; Samui & Kothari, 2011), Dans lequel  $t$  représente le nœud de la Spline :

$$y = f(x) = \beta_0 + \sum_{i=1}^k c_i B_i(x) \quad (\text{III.26})$$

Où

$y$ : est la variable cible,

$\beta_0$ : est une constante,

$c_i$  : est un vecteur de coefficients de la fonction de base non constante,

$B_i(x)$  : est la fonction de base définie sous la forme suivante :

$$(x - t)_+ = \begin{cases} x - t & x > t \\ 0 & x \leq t \end{cases} \quad (\text{III.27})$$

Et

$$(x - t)_- = \begin{cases} t - x & x < t \\ 0 & x \geq t \end{cases} \quad (\text{III.28})$$

Deuxièmement, un algorithme rétrograde élimine toutes les fonctions de base pour trouver la meilleure combinaison de nœuds existants. La validation croisée généralisée (**GCV**) est utilisée pour mesurer la qualité de l'ajustement et supprimer les fonctions de base inefficaces du modèle. **GCV** considère non seulement l'erreur résiduelle mais aussi la complexité du modèle. Les meilleurs sous-modèles ont des valeurs **GCV** plus faibles et le critère **GCV** est défini sous la forme suivante:

$$GCV = \left( \frac{1}{N} \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\left(1 - \frac{C(M)}{N}\right)^2} \right) \quad (III.29)$$

Où

$N$  est le nombre de données,  $M$  est le nombre de fonctions de base,  $y_i$  est la valeur de l'objet  $i$ ,  $\hat{y}_i$  la valeur de réponse prédite de l'objet  $i$ ,  $C(M)$  est une pénalité de complexité sous la forme suivante:

$$C(M) = \text{trace}(B(B^T B)^{-1} B^T) + 1 \quad (III.30)$$

Où  $B$  est la matrice de données  $M \times N$  des fonctions de base  $M$  (non constantes) (Friedman, 1991).

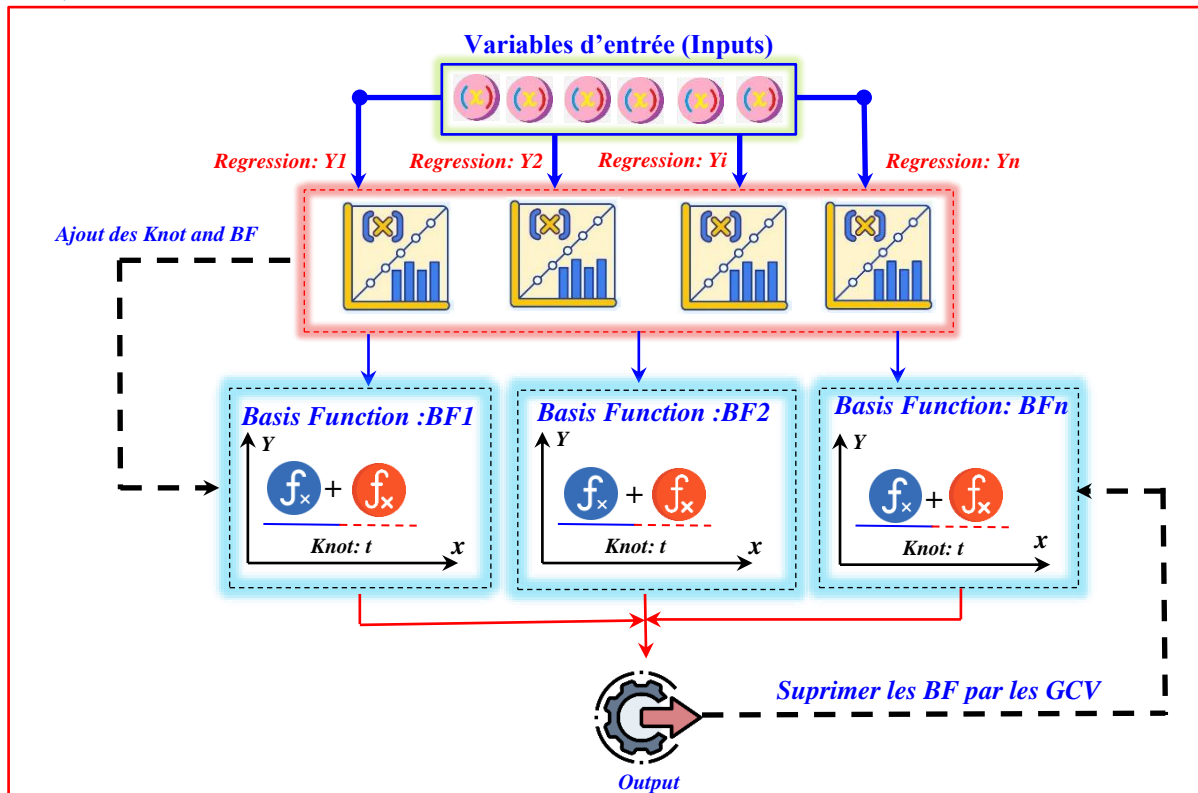


Figure III.7 . L'architecture détaillée du modèle MARS.

### III.9. M5 Model Tree (M5Tree)

Le modèle **M5** est un apprenant d'arbre de décision pour la tâche de régression, ce qui signifie qu'il est utilisé pour prédire les valeurs d'une variable numérique  $Y$ . L'arbre **M5** a été inventé par (Quinlan, 1992). L'arbre du modèle est donc analogue aux fonctions linéaires par morceaux (et donc non linéaires). Selon (Quinlan, 1992), l'arbre modèle **M5Tree** peut apprendre efficacement et peut gérer des tâches avec une dimensionnalité très élevée - jusqu'à des centaines d'attributs. Cette capacité distingue **M5Tree** des apprenants d'arbres de régression à l'époque (comme **MARS**), dont le coût de calcul augmente très rapidement lorsque le nombre

de fonctionnalités augmente. De plus, l'avantage de **M5Tree** est que les arbres modèles sont généralement beaucoup plus petits que les arbres de régression et se sont avérés plus précis dans les tâches étudiées (Quinlan, 1992). La construction d'un arbre modèle **M5Tree** consiste en deux étapes :

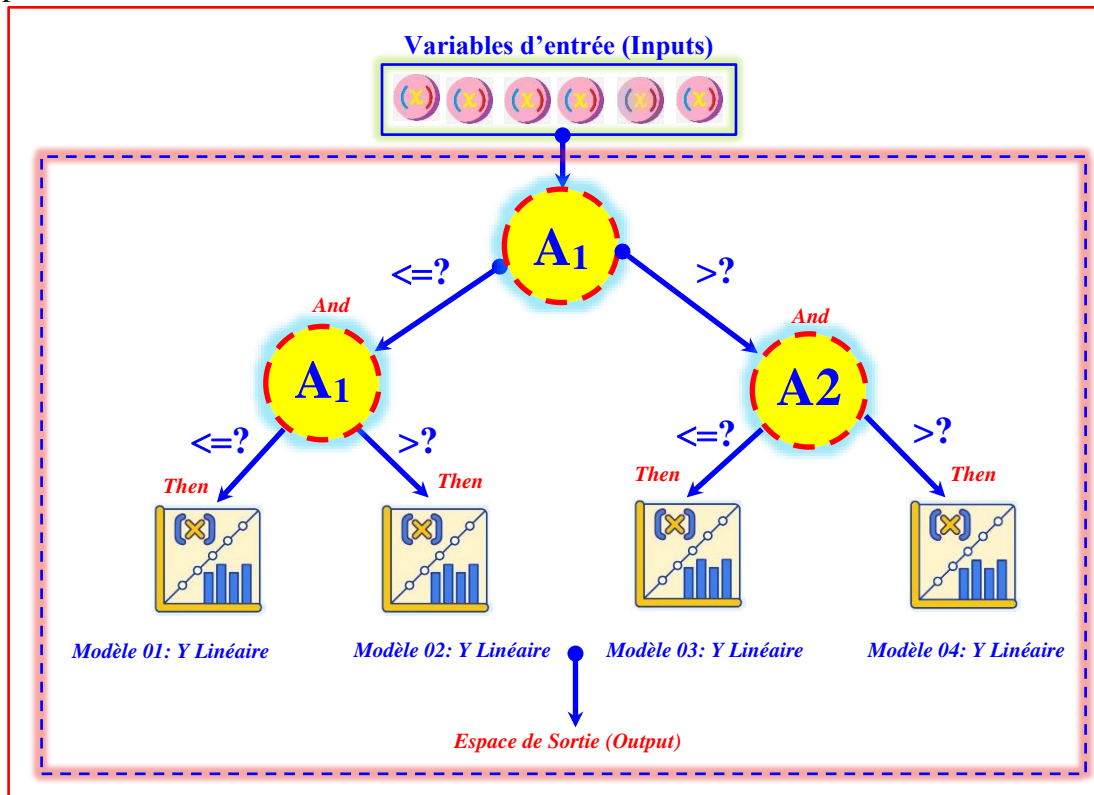


Figure III.8. L'architecture détaillée du modèle M5Tree.

- Création d'un arbre de décision en utilisant un critère de division et,
- Concevoir l'arbre modèle en élaguant l'arbre envahi (Singh et al., 2010).

Le fractionnement dans l'approche **M5Tree** applique l'idée d'un arbre de décision, mais au lieu des étiquettes de classe, il est composé de fonctions de régression linéaire aux feuilles, qui peuvent estimer des attributs numériques continus. Ce processus produit souvent des structures trop élaborées, à savoir le surajustement, qui doivent être élaguées. Considérons un ensemble d'exemples d'apprentissage  $T$  avec des paramètres indépendants comme entrée et la cible associée comme valeur de sortie. Les paramètres peuvent être soit associés à une feuille, soit découpés en sous-ensembles à l'aide d'un critère de découpage. Dans le **M5Tree**, l'écart type (**SD**) des valeurs de classe qui atteignent un nœud (en tant que mesure de l'erreur à ce nœud) est attribué comme critère de fractionnement. Par conséquent, la réduction de l'écart type (**SDR**) est utilisée pour calculer la réduction attendue de la  $sd$ .

$$SDR = sd(M) - \sum \frac{|T_i|}{|T|} sd(T_i) \quad (III.31)$$

Où :  $T$  représente les exemples d'apprentissage qui atteignent le nœud, et  $T_i$  désigne le sous-ensemble d'exemples avec le  $i^{\text{ème}}$  résultat de l'ensemble potentiel.

Le **M5Tree** choisira la structure associée au **SDR** maximisé. Cela pourrait conduire à la construction d'un grand arbre qui peut entraîner un surajustement. Pour faire face à cet inconvénient, dans la deuxième étape, l'arbre éventuellement envahi sera élagué (Kisi, 2015b, 2015a; Pal & Deswal, 2009). L'élagage est procédé d'une manière allant des feuilles au nœud racine. À chaque nœud interne, l'arbre **M5Tree** compare l'erreur estimée de ce nœud et l'erreur estimée du sous arbre ci-dessous. Ensuite, le sous arbre est élagué s'il n'améliore pas les performances de l'arbre.

### III.10. Conclusion

Dans le présent chapitre nous avons présenté les modèles à base d'intelligence artificielle que nous avons utilisée dans la présente étude. Les modèles sont respectivement :

1. Le réseaux de neurones perceptron multicouche (**MLPNN**).
2. Le réseaux de neurones à fonction de base radiale (**RBFNN**).
3. Le réseaux de neurones de régression généralisée (**GRNN**).
4. Les système d'inférence flou à base de réseaux de neurones adaptatifs (**ANFIS**) à base du clustering Soustractif (**ANFIS\_SC**).
5. Les système d'inférence flou à base de réseaux de neurones adaptatifs (**ANFIS**) à base du moyennes C-Floues (**ANFIS\_FC**).
6. Les modèles **M5Tree**
7. Les modèles de régression adaptative multivariée (**MARS**)
8. Les modèles à base des machines à vecteurs de support des moindres carrées (**LSSVM**)

---

**Chapitre IV : Modélisation des Débits de Fuite par  
les Techniques à Base l'Intelligence Artificielle &  
Etat de l'Art**

---

## IV.1. Introduction

L'analyse de l'infiltration joue un rôle crucial dans la sécurité et la stabilité des barrages, en particulier dans les applications de génie hydraulique, environnemental et civil. La prédiction précise et la modélisation de l'écoulement d'infiltration sont essentielles pour évaluer les performances et l'intégrité des structures de barrage. Ces dernières années, l'application des méthodes d'intelligence artificielle (IA) s'est révélée être une approche prometteuse pour améliorer la prédiction et la compréhension des phénomènes d'écoulement d'infiltration. Les méthodes traditionnelles d'étude du comportement de l'infiltration telles que les tests en laboratoire et sur le terrain, présentent des limites en termes de coût, de temps et de scalabilité. De plus, la nature complexe des processus d'infiltration implique souvent des relations non linéaires et incertaines, ce qui rend difficile le développement de modèles prédictifs précis à l'aide de techniques conventionnelles. Pour surmonter ces limites, les chercheurs se sont tournés vers les modèles d'IA, qui offrent des approches efficaces pour analyser de grandes quantités de données, traiter la non-linéarité et capturer des schémas complexes.

L'utilisation des méthodes d'IA dans la prédiction de l'écoulement d'infiltration présente plusieurs avantages. Ces modèles, tels que les réseaux de neurone artificiels (**ANN**), les machines à vecteurs de support (**SVM**), la programmation génétique (**GP**) et les systèmes d'inférence floue (**IF**), sont capables de capturer les relations complexes entre les variables d'entrées et l'écoulement d'infiltration. Les modèles d'IA sont faciles à utiliser, rapides en calcul et offrent une précision acceptable, ce qui en fait des alternatives attrayantes pour la modélisation de l'infiltration. Des études récentes ont comparé les modèles d'IA aux analyses numériques traditionnelles et aux données d'instrumentation pour valider leur efficacité dans la prédiction de l'écoulement d'infiltration. Cependant, l'application des modèles d'IA pour la prédiction de l'écoulement d'infiltration est encore un domaine en évolution. Les chercheurs explorent différentes méthodes d'informatique molle et tendances de recherche pour améliorer la précision et la fiabilité de la modélisation de l'infiltration. Ils cherchent à élargir la portée des modèles d'IA en tenant compte de propriétés d'infiltration supplémentaires, telles que la pression interstitielle et la conductivité hydraulique, et en explorant diverses méthodes d'étanchéité des barrages. Ces avancées contribuent à une meilleure compréhension du comportement de l'écoulement d'infiltration et améliorent l'évaluation de la sécurité des barrages.

Il existe une grande variété d'algorithmes de **ML** qui peuvent être utiles pour l'analyse des données de surveillance des barrages. Leur précision dépend des caractéristiques spécifiques de chaque tâche de prédiction. Étant donné que la recherche sur le **ML** est un domaine très actif, les algorithmes sont constamment améliorés et de nouvelles applications pratiques sont rapportées chaque année. Certaines d'entre elles ont été appliquées à l'analyse de la surveillance des barrages. Ils sont examinés dans cette section plus brièvement que d'autres, par leur faible popularité dans l'ingénierie des barrages jusqu'à présent ([Karapataki & Adamowski, 2012](#)).

Dans ce chapitre, nous présentons un aperçu de l'état de l'art de la prédiction de l'écoulement d'infiltration (**débit de fuite**) à travers les barrages en utilisant des approches d'**IA**

et de machine learning (**ML**). Nous passons en revue les études pertinentes, les méthodologies et les avancées dans le domaine de la modélisation de l'infiltration basée sur l'**IA**. De plus, nous mettons en évidence l'efficacité des différents modèles d'**IA** dans la prédiction de l'écoulement d'infiltration et discutons du besoin d'informations abondantes pour améliorer la précision de ces modèles. En examinant les tendances de recherche et les défis.

## IV.2. Modélisation du Débit de Fuite par les Modèles ANN

Dans des études récentes, des chercheurs se sont penchés sur le problème de l'infiltration d'eau à travers les barrages dans des conditions hydrauliques et des couvertures d'argile. (Salmasi & Nouri, 2019) ont examiné l'efficacité d'une couverture imperméable pour réduire les infiltrations et améliorer la stabilité des barrages en remblai. Leur étude a été basé sur des simulations numériques pour générer des données couvrant différentes configurations de couverture en amont. Les résultats ont été utilisés pour développer des diagrammes de conception, des modèles de régression et des modèles de réseaux de neurones artificiels (**ANN**). Il a été démontré qu'une couverture imperméable de longueur et d'épaisseur appropriées pouvait réduire efficacement les infiltrations et améliorer la stabilité du barrage. Le modèle de **ANN** a également montré d'excellentes performances dans la prédiction des infiltrations. (Miao et al., 2012) ont proposé un nouveau modèle **ANN** appelé "Algorithme Génétique pour Levenberg-Marquardt" (**GA-LM**) pour prédire l'infiltration dans un barrage en terre en Chine. Cette étude a utilisé 381 données de terrain, dont 366 en 2008 ont été utilisées pour l'apprentissage et 15 en 2009 pour les tests. Des variables tels que le niveau d'eau des réservoirs, les précipitations moyennes et les températures moyennes, ont été pris en compte. L'algorithme Levenberg-Marquardt a été utilisé pour entraîner le modèle **ANN**, et l'algorithme génétique a été utilisé pour optimiser sa structure. Les valeurs prédites d'infiltration obtenues à l'aide du modèle **GA-LM** étaient en accord satisfaisant avec les données de terrain.

(JAMEL & ALI, 2021) ont utilisé un modèle **ANN** basé sur les résultats de **GeoStudio** pour évaluer l'impact des infiltrations sur la stabilité d'un barrage en terre. L'étude a examiné à la fois l'écoulement en régime permanent et l'écoulement non-permanent pour la charge hydraulique amont, et a obtenu des équations empiriques pour estimer l'infiltration et la stabilité. Les résultats ont montré que le modèle **ANN** était capable de représenter avec précision les modèles de sortie pour les deux types d'écoulement, avec un degré élevé de précision. (Saleh, 2018) a développé un modèle **SEEP/W** pour mesurer le taux d'infiltration et le gradient de sortie sous des barrages en béton équipés de palplanches. Les variables indépendantes telles que la différence de niveau, le coefficient de perméabilité du sol, ainsi que l'espacement, la longueur et l'inclinaison des palplanches ont été utilisées pour améliorer la précision des résultats. Deux modèles de réseaux de neurones artificiels (**ANN**) ont été créés. Les résultats ont montré que le coefficient de perméabilité du sol était le facteur le plus influent sur le taux d'infiltration, tandis que la distance entre les palplanches avait le plus grand impact sur le gradient de sortie.

(De Granrut et al., 2019) ont appliqué modèle **ANN** pour analyser les pressions de soulèvement dans un barrage voûte français caractérisé par l'ouverture de l'interface roche-

béton. Le modèle de régression multilinéaire classique (**MLR**), s'est avéré insuffisant pour décrire ce phénomène hautement non linéaire et ses effets de seuil. Les auteurs ont effectué une analyse de sensibilité pour diagnostiquer l'évolution de l'ouverture de l'interface et ajuster le réseau en utilisant une étude paramétrique intégrant des éléments physiquement interprétables. Les résultats ont montré que le modèle **ANN** était très efficace et interprétable pour l'étude des phénomènes non linéaires, offrant des avantages pour la surveillance opérationnelle. ([Al-Juboori & Datta, 2019](#)) ont développé des modèles de substitution précis pour l'infiltration des barrages en utilisant des modèles **ANN** optimisés à l'aide d'un solveur d'algorithme génétique afin de prendre en compte à la fois les facteurs de sécurité et le coût de construction minimum.

#### **IV.2.1. Modélisation du Débit de Fuite par les modèles MLPNN :**

Parmi les différents types d'**ANN**, les réseaux neurone de perceptron multicouche (**MLPNN**) ont été particulièrement populaires en raison de leur capacité à modéliser des relations hautement non linéaires et de leur flexibilité dans le traitement de différents types de données d'entrée. Au cours des dernières années, les réseaux de neurones artificiels de type perceptron multicouches (**MLPNN**) ont émergé comme un outil de prédiction précis pour les débits d'infiltration et les pressions interstitielles dans les structures de barrage. Dans cette revue, nous examinons les avancées récentes dans l'utilisation des **MLPNN** pour modéliser les débits d'infiltration dans les barrages, en mettant l'accent sur les techniques de modélisation **MLPNN** et les approches d'apprentissage profond. ([Ranković et al., 2014](#)) ont exploré l'utilisation des modèles **MLPNN** pour prédire les niveaux piézométriques dans les barrages. Le modèle **MLPNN** a été entraîné à l'aide d'un algorithme de propagation résilient amélioré et de données expérimentales collectées sur une période de 9 ans. Les résultats ont démontré que le modèle **MLPNN** était capable de fournir des prédictions précises des niveaux piézométriques, surpassant les méthodes traditionnelles telles que la régression linéaire multiple (**MLR**). ([Markovic et al., 2021](#)). Ont proposé une nouvelle méthode utilisant des **MLPNN** pour prédire les pressions interstitielles dans les cellules de pression défectueuses. Leur étude a démontré que l'utilisation des **MLPNN** comme un modèle non linéaire permettait d'obtenir des résultats plus précis par rapport aux modèles linéaires. Dans l'article de ([Sharghi et al., 2018](#)), un modèle basé sur l'intelligence artificielle (**IA**) a été proposé pour modéliser les infiltrations dans les barrages en remblai de terre de Sattarkhan, situé dans le Nord-Ouest de l'Iran. Les résultats ont montré que l'approche d'assemblage améliorait les performances de modélisation de l'**IA** jusqu'à 20% lors de la phase de vérification. Ces études mettent en évidence l'efficacité des **FNN** pour la modélisation des débits d'infiltration dans les barrages, offrant ainsi de nouvelles perspectives pour l'ingénierie des barrages et la gestion de leur sécurité.

([Parsaie et al., 2021](#)), ont été utilisés le modèle de réseaux de neurone **MLPNN** pour prédire le niveau piézométrique et le débit d'infiltration dans un barrage terrestre. Les données des 94 derniers mois du barrage Shahid Kazemi Bukan ont été utilisées. Les résultats ont montré que le modèle avait un niveau de précision admissible dans la prédiction des niveaux piézométriques et pour la prédiction des décharges d'infiltration. ([Khoramshokooh et al., 2018](#)) ont utilisé un modèle de simulation-optimisation pour déterminer les caractéristiques de conception structurales optimales des murs de séparation sous le barrage de dérivation. À cette fin, ils ont utilisé des modèles de réseaux de neurones **MLPNN** pour prédire le comportement

hydraulique des parois parafouilles. Les résultats du modèle MLPNN ont été comparés avec celles obtenus par le logiciel **GeoStudio**.

(Zhou et al., 2015) ont mis au point une nouvelle approche pour la modélisation inverse de l'écoulement transitoire des eaux souterraines dans les fondations de barrages. Leur méthode consistait à créer une fonction objective basée sur des mesures de la charge hydraulique et des séries chronologiques d'infiltration, avec un coefficient de pondération qui garantissait des dimensions d'expression égales des erreurs relatives. Ils ont utilisé une conception orthogonale, une modélisation directe du flux d'infiltration transitoire à l'aide de méthodes par éléments finis, un réseau de neurone de rétropropagation **MLPNN** et un algorithme génétique (**GA**), ce qui a considérablement réduit le coût de calcul. De même, (Vaezinejad et al., 2018) ont introduit une nouvelle méthode combinée qui utilise la conception orthogonale, **MLPNN** et **GA** pour effectuer une modélisation inverse de l'infiltration à partir du corps et des barrages terrestres. Dans les études de (X. Zhang et al., 2020), les modèles (**MLPNN**) combinées à l'algorithme génétique (**GA**) ont été utilisées pour le modèle de prédiction des infiltrations de barrage. En considérant un barrage typique en Chine comme étude de cas, les résultats de prédiction du modèle **MLPNN-GA** et du modèle statistique ont été comparés aux valeurs de surveillance instrumentale. Les résultats ont montré que le modèle amélioré d'infiltration des barrages améliore la capacité de généralisation non linéaire et rend la prévision des infiltrations plus précise et raisonnable dans un proche avenir.

**Tableau IV. 1.** Modèles à base de réseaux MLPNN pour la modélisation du débit de fuite.

| Auteurs             | Année | Pays              | Inputs   | Output                    | Models            | performances   |
|---------------------|-------|-------------------|--|---------------------------|-------------------|--|
| Ranković et al.     | 2014  | Serbia et Romania | $H_{wt}, H_{wt-1}, H_{wt-2}$   | $PZ_t$                    | MLPNN             | <b><math>R^2= 0.98,</math><br/><b><math>MSE = 0,45</math></b></b>    |
| Markovic et al.     | 2021  | Serbie            | PZ1, PZ3 à PZ16  | PZ2                       | MLPNN             | //   |
| Sharghi et al.      | 2018  | Iran              | $PZ_{t-1}, PZ_{t-2}, \dots, PZ_{t-n}, H_{wt-1}, H_{wt-2}, \dots, H_{wt-n}$ | $PZ_t$ (m)                | MLPNN, SVR, ANFIS | <b><math>DC= 0.927,</math><br/><b><math>RMSE= 0.029</math></b></b>   |
| Parsaie             | 2021  | Iran              | $H_w(t-3), H_w(t-2), H_w(t-1), H_w(t)$                                     | $Q_s, H_p(t)$             | MLPNN             | <b><math>R^2=0.955,</math><br/><b><math>RMSE= 0.843</math></b></b>   |
| Khoramshokoh et al. | 2018  | Australia         | $X_1, X_2, X_3$  | $h_1, h_2, h_3, h_4, h_5$ | MLPNN,            | <b><math>R^2 = 0.9195</math></b>                                     |
| Zhou et al.         | 2015  | Chine             | $k_1 \dots k_m, \phi_1 \phi_n$   | $Q_{jt}^m$                | MLPNN + GA        | //   |
| Vaezinejad et al.   | 2018  | Iran              | $k_1 \dots k_m, \phi_1 \phi_n$   | $Q_{jt}^m$                | MLPNN + GA        | //   |
| Zhang et al.        | 2020  | Chine             | Date(JJ ;M M ;AA) ; température ; CPE                                      | Pression de soulèvement   | MLPNN - GA        | <b><math>MSE: 0.0202,</math><br/><b><math>MAE: 0.0736</math></b></b> |

- **Hw**: les mesures des hauteurs d'eau prises le même jour (t), 1 jour avant (t-1) et 2 jours avant (t-2)
- **X1** : Profondeur de la paroi d'étanchéité amont ; **X2** : Profondeur de la paroi d'étanchéité aval ; **X3** : Distance entre deux parois d'étanchéité
- **h1** : Débit d'écoulement par infiltration à travers la fondation du barrage de dérivation, **h2** : Force de soulèvement sous le corps du barrage de dérivation, **h3** : Gradient hydraulique horizontal à la base du barrage de dérivation, **h4** : Gradient hydraulique vertical à la base du barrage de dérivation, **h5** : Coût global de l'application de la paroi d'étanchéité
- **k1.. km** : les conductivités hydrauliques des milieux  $\phi_1... \phi_n$  : les mesures en séries temporelles ;  $Q_{jt}^m$  : piézomètre i, : la mesure du débit au débitmètre j et au temps t.

#### IV.2.2. Modélisation Du Débit De Fuite par les modèles RBFNN :

Les réseaux de neurone à fonction de base radiale (**RBFNN**) sont de plus en plus utilisés pour la modélisation des flux d'infiltration à travers les barrages en raison de leur capacité à capturer avec précision les relations non linéaires. Dans cette revue de pointe, nous examinerons les dernières recherches sur les applications des réseaux de neurone **RBFNN** pour la modélisation des débits de fuite à travers les barrages. (Nourani & Babakhani, 2013) ont utilisé le modèle **RBFNN** pour estimer le débit de fuite à travers les barrages en terre. Ils ont comparé les résultats du modèle **RBFNN** avec les résultats de la solution numérique des équations de Laplace. Les résultats de la modélisation et de la prévision à l'aide du modèle **RBFNN** montrent qu'elle est plus précise que la méthode des différences finies. Les résultats ont montré l'efficacité du modèle **RBFNN**. (Roushangar et al., 2016) ont utilisé la fonction de base radiale (**RBF**) comme outil de base dans leur modèle de régression de processus gaussien (**GPR**) pour prédire le débit d'infiltration dans les barrages en terre. Le noyau RBF a été optimisé à l'aide de la validation croisée pour obtenir les meilleurs résultats de prédiction. Les auteurs ont recueilli des données quotidiennes à partir de 27 piézomètres et du niveau du réservoir, et ils ont utilisé les ondelettes d'information mutuelles pour identifier les variables d'entrée les plus pertinentes pour le modèle **GPR**. Les résultats ont montré que la meilleure prédiction a été réalisée en utilisant la combinaison du niveau du piézomètre et du niveau du réservoir.

**Tableau IV. 2.** Modèles à base de réseaux RBFNN pour la modélisation du débit de fuite.

| Auteurs               | Année | Pays | Inputs  | Output  | Models      | performances                     |
|-----------------------|-------|------|---|---|-------------|----------------------------------|
| Nourani and Babakhani | 2013  | Iran | $Hw_{amont_i}^{t+1}$ ,<br>$Hw_{aval_i}^{t+1}$ , P<br>$Z_1^t$ a $PZ_3^t$ | $Hw_1^{t+1}$<br>À (n'importe quel point souhaité) | RBFN<br>N   | $R^2 = 0.8665$ ,<br>RMSE = 0.866 |
| Roushangar et al.     | 2016  | Iran | $PZ_t^i$ , $Hw_t^i$   | Q(L/mn)   | GPR+<br>RBF | R= 0.980,<br>RMSE= 0.048         |

### IV.3. Modélisation du Débit de Fuite par les modèles MLR et MNL

Le modèle **MLR** utilise la régression des moindres carrés, ce qui signifie qu'il minimise la somme des carrés des différences entre les valeurs prédites et réelles. L'un des principaux avantages de cette approche est sa simplicité et sa facilité de mise en œuvre. Cependant, le modèle **MLR** présente certaines limites lorsqu'il s'agit de prédire des situations spécifiques, en particulier celles impliquant des relations non linéaires ou de grandes quantités de bruit dans les données. Essentiellement, cette méthode exprime une variable de réponse comme une fonction linéaire d'une ou plusieurs variables prédictives, avec un terme d'erreur. (Taurino et al., 2003). Dans l'étude d'(El Bilali et al., 2022), les modèles **MLR**, **ANN**, **SVR** et **adaptive Boosting (AdaBoost)** avec entrées exogènes autorégressives non linéaires (**NARX**) sont proposés pour intégrer le délai de réponse du barrage à la charge hydraulique. Ainsi, ces modèles ont été évalués et comparés au modèle **HST** pour prédire la pression quotidienne de l'eau interstitielle dans un barrage en remblai. De plus, ils ont proposé une méthode de classification des modèles en quatre catégories, parfait, excellent, bon et médiocre selon l'**AG**. Les résultats ont montré que, à l'exception de l'AdaBoost, les autres modèles **ML** ont surpassé l'approche statistique traditionnelle (**HST**) en termes de précision de la prédiction ainsi que l'**AG**. Dans l'étude de (Rehamnia et al., 2020), le modèle **MLR** a été utilisé comme référence pour comparer le rendement des trois modèles d'**IA** qui ont été développés pour prédire l'écoulement des infiltrations à travers les roches de façade en béton et les barrages d'écluse. Le modèle **MLR** leur a permis d'évaluer si les modèles d'**IA** pouvaient améliorer les prédictions faites par le modèle de régression linéaire standard.

**Tableau IV. 3.** Modèles MLR et MNL pour la modélisation du débit de fuite.

| Auteurs         | Année | Pays    | Inputs                        | Output            | Models                        | Performances                                      |
|-----------------|-------|---------|-------------------------------|-------------------|-------------------------------|---|
| El Bilali et al | 2022  | Morocco | PZ1 A PZ11, CPE (2010 a 2019) | PZ1 A PZ11 (2020) | MLR, NARX, SVR, ANN, AdaBoost | <b>R<sup>2</sup>= 0.996,</b><br><b>RMSE=0.007</b> |
| Rehamnia et al. | 2019  | Algérie | PZ1 a PZ7, CPE                | Q (l/s)           | MLR                           | <b>R=0.895,</b><br><b>RMSE = 0.611</b>            |

### IV.4. Modélisation du Débit de Fuite par les modèles à base de noyau.

(S. Chen et al., 2020) ont formé une machine d'apprentissage extrême à base de noyau (**KELM**) pour prédire les fuites au niveau des barrages, où les paramètres sont optimisés de manière adaptative par un algorithme parallèle de Jaya multi-population. Les données de surveillance de l'écoulement des fuites du barrage en enrochement dans une centrale de pompage-turbinage sont utilisées pour la modélisation. Les résultats simulés révèlent que **KELM** permet une prédiction satisfaisante du flux de fuite. On constate également que la fluctuation des niveaux d'eau et les précipitations ont un impact significatif sur l'ampleur des fuites. De plus, (Sharghi et al., 2019) , (Belmokre et al., 2019) et (Sharghi et al., 2018) ont

utilisé le modèle **SVR** dans leurs études. Les résultats indiquent que la précision de la prédiction et la capacité de détection des valeurs aberrantes du flux de fuite à l'aide du **KELM** adaptatif sont meilleures que celles du **MLR**, de l'**ELM** et de la **RFR**. L'algorithme de machine à vecteurs de support (**SVM**) a été largement appliqué à la modélisation des débits de fuite en raison de sa capacité à gérer des relations complexes et non linéaires entre les variables d'entrée et de sortie. Dans cette revue, nous discuterons des applications de pointe de la **SVM** pour la modélisation des débits de fuite. Le **SVM** est un algorithme d'apprentissage supervisé qui construit un hyperplan dans un espace de grande dimension pour séparer les points de données en différentes classes. L'algorithme cherche à trouver l'hyperplan qui maximise la marge entre les classes, la marge étant la distance entre l'hyperplan et les points de données les plus proches de chaque classe. La **SVM** peut être utilisée pour les tâches de classification et de régression (i.e., **SVR**). Dans la modélisation des débits de fuite, la **SVM** a été principalement utilisée pour les tâches de régression.

L'article de (Su et al., 2016) traite l'utilisation de modèles basés sur les **SVM** pour surveiller la sécurité des bâtiments et prévoir le comportement structurel des barrages tels que le déplacement, les contraintes et les infiltrations.

Dans l'étude de (Wang et al., 2018), deux modèles de surveillance ont été développés pour prédire et évaluer la tendance de développement à long terme et la fluctuation à court terme du comportement d'infiltration des barrages. Le premier modèle séparait les valeurs de base de l'élément d'infiltration et du niveau d'eau du réservoir de leur composante d'effet temporel à l'aide de la méthode d'analyse multi résolution par ondelettes. Le deuxième modèle était basé sur les **SVM** et visait à optimiser le facteur d'entrée défini pour la variation quotidienne des éléments d'infiltration du barrage. Dans l'étude de (Tinoco et al., 2020), l'objectif était de comparer les performances prédictives et les capacités de généralisation de six algorithmes d'exploration de données différents susceptibles d'être utilisés à des fins de surveillance dans le cas particulier de la piézométrie à l'interface des barrages voûtés : **ANN**, **SVM**, arbre de décision (**DT**), **K**-plus proche voisin (**KNN**), forêt aléatoire (**RF**) et régression multiple (**MR**). Les modèles sont utilisés pour analyser les mêmes séries chronologiques. Les résultats obtenus montrent que **SVM** et **ANN** se distinguent comme les algorithmes les plus efficaces lorsqu'il s'agit d'analyser des phénomènes surveillés non linéaires.

**Tableau IV. 4.** Modèles à base de noyau pour la modélisation du débit de fuite.

| Auteurs        | Année | Pays  | Inputs                                     | Output  | Models                            | Performances   |
|----------------|-------|-------|--|---------|-----------------------------------|--|
| Chen et al.    | 2020  | Chine | Date (MM, AA),<br>Précipitation,<br>CPE    | Q (l/s) | KELM                              | <b>MAE= 0.678,</b><br><b>NRMSE=</b><br><b>0.041</b>          |
| Sharghi et al. | 2019  | Iran  | Pt-1,Pt-2....Pt-n,<br>Hwt-1,Hwt-2....Hwt-n | Pt (m)  | MLPNN,<br>ANFIS,<br>SVR,<br>ARIMA | <b>R<sup>2</sup>=0.7700,</b><br><b>RMSE=</b><br><b>0.038</b> |

|                |        |         |  |                      |                        |  |
|----------------|--------|---------|--|----------------------|------------------------|--|
| Belmokre et al | 2019   | Algérie | Hw , Tw , T  | Q (l/s)              | RF, SVR                | <b>R= 0.0327,</b><br><b>RMSE = 0.0629</b>          |
| Sharghi et al. | 2018   | Iran    | Pt-1,Pt-2....Pt-n, Hwt-1,Hwt-2....Hwt-n                              | Pt (m)               | MLPNN, SVR, ANFIS      | <b>DC= 0.883,</b><br><b>RMSE= 0.038</b>            |
| Su et al.      | (2015) | Chine   | Hw ;<br>Température ;<br>Déformation plastique                       | Déplacement de digue | SVM                    | <b>MSE 0.0007</b><br><b>R<sup>2</sup>= 0.9884</b>  |
| Wang et al.,   | 2018   | Chine   | CPE ;<br>précipitation ;<br>Température ;                            | PZ ; Q               | SVM                    | <b>MSE 0.0049</b>                                  |
| Tinoco et al   | 2020   | France  | PZ <sub>i</sub> , T <sub>i</sub> , CPE <sub>i</sub> , S <sub>i</sub> | PZ                   | SVM ,<br>ANN,<br>DT... | <b>R<sup>2</sup>= 0.986,</b><br><b>RMSE= 0.18.</b> |

- La saison **Si** qui est un angle égal à 0 au 1er de janvier et 360 le 31 décembre

#### IV.5. Modélisation du Débit de Fuite par les modèles MARS

MARS (Régression multivariée par Spline adaptative) est un autre modèle qui a été utilisé pour la modélisation du débit de fuite. MARS utilise un ensemble de fonctions Spline Adaptatives pour modéliser les relations non linéaires entre les variables d'entrée et de sortie. **MARS** est utilisé pour modéliser le débit de fuite en raison de sa capacité à saisir les relations non linéaires entre les variables d'entrée et de sortie et à gérer les données manquantes. (Rehamnia et al., 2020) ont appliqués trois modèles à base de l'intelligence artificiel dans le but de comparaison : (i) (**MARS**), (ii) **LSSVM** (Least-squares support-vector machines), et (iii) **M5Tree**, pour prédire le débit de fuite à travers deux barrages : le barrage enrochement a masque amont en béton de Al Agrem Willaya Jijel et le barrage en remblai de Fontaine Gazelles de la Willaya de Biskra. Ils ont utilisé comme entrées les mesures journalière la cote plan d'eau (**CPE**) dans le réservoir et les niveaux piézométriques (**NP**) dans sept piézomètre différent. Les résultats ont montré que la meilleure précision de prédiction a été obtenue par le modèle **LSSVM** suivi du **MARS** et du **M5Tree** en troisième position. Dans l'article de (Kumar et al., 2019), la stabilité du remblai de terre de Durgawati en Inde a été analysée à l'aide de deux méthodes, les modèles (**MARS**) et la machine à vecteurs de pertinence (**RVM**). L'étude a calculé l'indice de fiabilité du barrage dans des conditions d'infiltration en régime permanent et en état transitoire en utilisant **MARS** et **RVM**. Les résultats des calculs de l'indice de fiabilité indiquent que la performance du barrage est satisfaisante. Pour prédire la hauteur piézométrique dans le noyau et la décharge d'infiltration à travers le corps du barrage en terre, (Parsaie et al., 2021) ont utilisés les modèles **MLPNN**, **SVM**, **MARS**, la programmation génétique (**GP**), **M5Tree** et la méthode de traitement des données en groupe (**GMDH**). Les données enregistrées pendant les 94 derniers mois de du barrage Shahid Kazemi Bukan ont été utilisées. Les résultats ont montré que tous les modèles appliqués avaient un niveau de précision acceptable dans la

prédiction des hauteurs piézométriques, pour ce qui est de la prévision des débits de fuite, les modèles étaient presque identiques avec une légère supériorité pour le modèle **MARS**, alors que le modèle **M5Tree** était le plus faible.

**Tableau IV. 5.** Modèles MARS pour la modélisation du débit de fuite.

| Auteurs         | Année | Pays    | Inputs                | Output                      | Modèles                   | Performances  |
|-----------------|-------|---------|-----------------------|-----------------------------|---------------------------|---|
| Rehamnia et al. | 2020  | Algérie | PZ1 a<br>PZ7,<br>CPE  | Q (l/s)                     | MARS,<br>LSSVM,<br>M5tree | <b>R= 0.939</b> ,<br><b>RMSE=</b><br><b>0.470</b>             |
| Kumar et al.,   | 2019  | Inde    | C', $\delta$ , $\Phi$ | L'indice<br>de<br>fiabilité | MARS,<br>RVM              | <b>R<sup>2</sup>= 0.873</b> ,<br><b>RMSE=</b><br><b>0.227</b> |

- **C** : Cohésion ;  **$\delta$**  : Poids unitaire du sol ;  **$\Phi$**  : Angle de frottement interne

## IV.6. Modèle D'arbre de Décision Pour La Modélisation du Débit de Fuite :

La modélisation des écoulements d'infiltration est une tâche importante dans diverses applications techniques et environnementales, telles que la gestion des eaux souterraines, l'analyse de la sécurité des barrages et l'ingénierie géotechnique. Les modèles arborescents, tels que les arbres de décision, les forêts aléatoires et les machines d'amplification de gradient, ont été largement appliqués à la modélisation des flux d'infiltration en raison de leur capacité à gérer des relations complexes et non linéaires entre les variables d'entrée et de sortie. Les arbres de décision sont un type d'algorithme d'apprentissage supervisé qui construit un modèle arborescent des décisions et de leurs conséquences possibles. Chaque nœud interne de l'arbre représente un test sur un attribut, chaque branche représente le résultat du test et chaque nœud feuille représente une décision ou une prédiction. Les arbres de décision ont été largement appliqués à la modélisation des flux d'infiltration en raison de leur capacité à gérer les relations non linéaires entre les variables d'entrée et de sortie et de leur intelligibilité.

### IV.6.1. M5Tree Pour La Modélisation Du Débit Des Fuites

**M5Tree** est un algorithme basé sur un arbre de décision qui a été largement utilisé pour prédire différentes variables dans divers domaines, notamment les ressources en eau, la surveillance environnementale et le génie civil. Ses avantages comprennent la facilité d'utilisation, les prévisions rapides et précises et l'interprétabilité des résultats. Dans l'ensemble, l'étude montre que **M5Tree** est un outil utile pour prédire les d'infiltration dans les barrages en terre et a un potentiel d'application dans d'autres domaines. (Najafzadeh, 2020) a appliqué plusieurs modèles de calcul y compris l'algorithme **M5Tree**, pour prédire le débit d'infiltration dans le barrage terrestre Shahid Kazemi Boukan. L'algorithme **M5Tree** a atteint une précision raisonnable dans la prédiction de débit de fuite, avec un **R<sup>2</sup>** de 0.92 et **RMSE** de 1.541, et a surpassé les autres modèles de Soft-Computing. Parmi ces études figure celle de (Parsaie et al., 2021; Rehamnia et al., 2020; Ziggah et al., 2022). Dans une étude de (Parsaie et al., 2021), le modèle M5Tree a été utilisé pour prédire le débit d'infiltration dans le barrage

dans un barrage en terre de Shahid Kazemi Bukan en Iran. Dans une autre étude de (Rehamnia et al., 2020), le modèle M5Tree a été utilisé pour prédire le débit d'infiltration à travers les deux barrages, le barrage enrochement a masque amont en béton de Al Agrem de la Willaya Jijel et le barrage en remblai de Fontaine Gazelles de la Willaya de Biskra en Algérie. L'étude de (Ziggah et al., 2022) s'est concentrée sur la prévision du débit d'infiltration dans un barrage en terre à l'aide du modèle **M5Tree**. Ces études démontrent l'efficacité du modèle **M5Tree** dans la prédiction du débit d'infiltration et son potentiel à être utilisé comme outil de gestion de la sécurité des barrages.

**Tableau IV. 6.** Modèles M5Tree pour la modélisation du débit de fuite.

| Auteurs         | Année | Pays    | Inputs  | Output    | Models                   | Performances  |
|-----------------|-------|---------|---|-----------|--------------------------|---|
| Najafzadeh      | 2020  | Iran    | Hw(t-2), Hw (t-1), Hw (t)                           | Qs        | M5tree, GEP, GMDH        | <b>R<sup>2</sup>=0.93,</b><br><b>RMSE= 1.239</b>    |
| Parsaie et al.  | 2021  | Iran    | Hw(t-3), Hw (t-2), Hw (t-1), Hw(t)                  | Qs, Hp(t) | M5tree, MLPNN, SVM, GMDH | <b>R<sup>2</sup>= 0.967,</b><br><b>RMSE= 0.747.</b> |
| Rehamnia et al. | 2020  | Algérie | PZ1 a PZ7, CPE                                      | Q (l/s)   | M5tree , LSSVM,MARS      | <b>R= 0.939 ,</b><br><b>RMSE= 0.470</b>             |
| Ziggah et al.   | 2022  | Ghana   | Module<br>Température<br>Pression<br>Précipitations | PZ(m)     | M5tree, GMDH, RBFNN, ... | <b>R= 0.9989 ,</b><br><b>RMSE=0,107</b>             |

#### IV.6.2. Forêt Aléatoire (RF) Pour La Modélisation Du Débit De Fuites

La forêt aléatoire (**RF**) est une méthode d'apprentissage supervisé qui utilise plusieurs arbres dans le processus de classification. L'algorithme de forêt aléatoire, en remplaçant et en modifiant continuellement les facteurs pertinents et liés aux objectifs, génère un grand nombre d'arbres de décision. Ensuite, tous les arbres sont combinés pour effectuer des prédictions. Au cours de la formation, les données principales générées par l'arbre sont sélectionnées de manière aléatoire. Une forêt aléatoire (**RF**) est définie par trois paramètres déterminés par l'utilisateur : (i) le nombre de variables utilisées pour construire chaque arbre, ce qui reflète la puissance de chaque arbre indépendant ; (ii) le nombre total d'arbres dans la forêt aléatoire ; (iii) le nombre minimum de nœuds terminaux. L'amélioration de la force des arbres indépendants et la réduction de leur corrélation entre eux augmentent la capacité prédictive de la forêt aléatoire. L'algorithme **RF** n'utilise pas toutes les données disponibles pour construire l'arbre, mais utilise plutôt 66% des données à partir d'un échantillon aléatoire avec remplacement, également appelé méthode de Bootstrap. Une variable prédictive est ensuite introduite aléatoirement pendant le processus de croissance de l'arbre. Cette variable est utilisée pour diviser un nœud de l'arbre de manière aléatoire, permettant ainsi à l'arbre de décision de devenir aussi complexe que possible. Les 33% de données restantes sont utilisées pour évaluer l'arbre ajusté. Ce processus est répété plusieurs fois et la moyenne de toutes les valeurs prédites est utilisée comme prédiction finale de l'algorithme **RF**.

(Belmokre et al., 2019) ont évalué les performances du modèle **RF** pour prédire le débit d'infiltration à différents points d'une étude de cas et identifier les variables environnementales les plus importantes qui affectent le débit. (Li et al., 2021) ont utilisé des données de surveillance réelles pour construire un modèle de surveillance de la sécurité des barrages basé sur l'algorithme intelligent **RF**. Ce modèle a été utilisé pour prédire la pression de soulèvement. Les résultats ont montré que le modèle **RF** était relativement rapide et capable de prédire avec précision la pression de soulèvement du barrage en fonction des facteurs d'influence. De plus, par rapport à d'autres algorithmes intelligents tels que les **SVM**, la **RF** présentait une meilleure robustesse, une plus grande précision de prédiction et une convergence plus rapide. L'étude d'(Ishfaqe et al., 2022) visait à prédire la quantité d'infiltration du barrage de Tarbela au Pakistan en utilisant des modèles d'apprentissage automatique, notamment l'algorithme de forêt aléatoire (**RF**). Les variables d'entrée comprenaient la température, les précipitations, l'apport en eau, l'apport en sédiments et le niveau du réservoir, tandis que la variable de sortie était le débit d'infiltration du barrage. L'étude a révélé que l'algorithme **RF** fonctionnait bien, avec des scores **R<sup>2</sup>** élevés pour les phases d'apprentissage et de test, dépassant ainsi les performances d'autres modèles d'apprentissage automatique tels que les **MLPNN** et les **SVM**.

**Tableau IV. 7.** Modèles de Forêt Aléatoire pour la modélisation du débit de fuite.

| Auteurs        | Année | Pays     | Inputs   | Output                  | Modèles                         | Performances                                       |
|----------------|-------|----------|--|-------------------------|---------------------------------|--|
| Belmokre et al | 2019  | Algérie  | CPE, Tw , Temps  | Q (l/s)                 | RF, SVR                         | <b>R= 0.0327,</b><br><b>RMSE = 0.0629</b>          |
| Li et al       | 2021  | Chine    | $Hw_{amont}$ , $Hw_{aval}$ ,<br>$Tw_{amont}$ , $Tw_{aval}$ ,<br>Précipitation    | Pression de soulèvement | RF, SVM                         | <b>MSE=0.560</b><br><b>99.32</b>                   |
| Ishfaqe et al  | 2022  | Pakistan | Débit d'eau entrée,<br>CPE, Débit solide entrée,<br>Température<br>Précipitation | Q(m <sup>3</sup> /s)    | ANN,<br>RF,<br>SVM,<br>CatBoost | <b>R<sup>2</sup>= 0.801,</b><br><b>RMSE= 0.077</b> |

- **Tw** : température de l'eau

#### IV.7. Le modèle Neuro-Floue pour la modélisation du Débit De Fuites

L'Adaptive Neurofuzzy Inference System (**ANFIS**) est une technique populaire d'intelligence artificielle utilisée dans la modélisation du débit d'infiltration. L'**ANFIS** est un modèle hybride qui combine les avantages des réseaux de neurones artificiels (**ANN**) et de la logique floue. Il utilise un ensemble de règles floues pour modéliser les relations non linéaires entre les variables d'entrée et de sortie. L'**ANFIS** est utilisé pour modéliser le débit d'infiltration en raison de sa capacité à gérer des relations complexes et non linéaires entre les variables et à traiter des données imprécises. Dans une étude réalisée par (Xue & Xiao, 2019) , le modèle **ANFIS** a été utilisé pour évaluer la stabilité interne des sols sous infiltration. Les résultats ont

démontré que le modèle **ANFIS** est un outil efficace et précis pour prédire la stabilité interne des sols. Une autre étude menée par (Heydari & Talaei, 2011), un autre modèle dit Coactive Neurofuzzy Inference System (**CANFIS**) a été utilisé pour prédire l'écoulement à travers des barrages en enrochement trapézoïdaux et rectangulaires. Les résultats ont montré que le **CANFIS** utilisant le modèle flou de Takagi-Sugeno-Kang (**TSK**), pouvait fournir des prévisions précises du débit à travers ces types de barrages. Les auteurs ont également identifié les algorithmes de Levenberg-Marquardt et de Delta-Bar-Delta comme étant les plus performants pour entraîner le réseau à estimer le débit à travers des barrages en enrochement rectangulaires et trapézoïdaux, respectivement. Dans l'article de (Sharghi et al., 2019), le modèles **ANFIS**, **MLPNN**, et **SVR** ont été proposé pour la modélisation des infiltrations à travers le barrage de remblai de terre de Sattarkhan en Iran.

**Tableau IV. 8.** Modèles Neuro-Floue pour la modélisation du débit de fuite.

| Auteurs           | Année | Pays  | Inputs                                   | Output | Modèles       | Performances                          |
|-------------------|-------|-------|--|--------|---------------|---------------------------------------|
| Xue et Xiao       | 2019  | China | Ta, Tf, Fs, Fg, Cu, Cc                   | Ss     | ANFIS, PSO-BP | Taux de précision= 100 %, RMSE= 0.027 |
| Heydari et Talaei | 2011  | Iran  | Hw <sub>amont</sub> , Hw <sub>aval</sub> | Q(L/s) | CANFIS        | R <sup>2</sup> = 0.975 , RMSE = 0.965 |

- **Ss** : L'état de stabilité ; **Ta** : teneur en argile ; **Tf** : teneur en particules fines ; **Fs** : La fraction de sable ; **Fg** : La fraction graveleuse ; **Cu** : coefficient d'uniformité ; **Cc** : Coefficient de courbure

#### IV.8. Modèles Hybrides pour la modélisation du Débit de fuite

D'autres modèles hybrides, tels que **GPR-RBF**, **PSO\_SVM** et **HGWO-XGBoost**, ont également été appliqués à la modélisation du débit de fuite. Ces modèles combinent les avantages de différentes techniques d'IA pour améliorer la précision et l'efficacité du processus de modélisation. Par exemple, une étude menée par (Jiang & Liang, 2006) visait à établir un modèle de séries chronologiques pour simuler les données de surveillance du débit d'infiltration des barrages en utilisant un modèle **SVR**. L'étude a utilisé l'optimisation de l'essaim de particules (**PSO**) pour optimiser les paramètres du modèle et a montré que le modèle **PSO\_SVM** était efficace pour prédire avec précision le débit d'infiltration des barrages, ce qui en fait un outil potentiel pour la surveillance et la gestion de la sécurité des barrages. Dans une autre étude menée par (K. Zhang et al., 2021), un nouveau modèle de surveillance des infiltrations pour les barrages en béton en utilisant l'optimisation de Gradient Extrême (**XGBoost**) et l'optimisation hybride du loup gris (**HGWO**) pour ajuster les hyperparamètres. Les résultats ont montré que le modèle **HGWO-XGBoost** fournissait des prévisions satisfaisantes pour l'infiltration des barrages, et l'étude a également identifié une méthode efficace pour calculer le décalage du niveau d'eau en amont et des précipitations.

(Rehamnia et al., 2021) ont développé un paradigme efficace d'intelligence des données en utilisant le filtre de Kalman étendu et les réseaux de neurones artificiels de type Feed Forward (**EKF-ANN**) pour estimer précisément le débit d'infiltration quotidien à travers un

barrage en remblai. L'étude a comparé l'**EKF-ANN** à d'autres approches d'apprentissage automatique telles que les **MLPNN**, les réseaux de fonctions de base radiales (**RFNN**) et les **RF**. Les résultats ont montré que l'**EKF-ANN** surpassait les autres modèles en termes de performance. En conclusion, les techniques d'intelligence artificielle hybrides sont de plus en plus utilisées dans la modélisation du débit d'infiltration des barrages. Ces approches, telles que l'**ANFIS**, le **GPR-RBF**, le **PSO\_SVM** et l'**HGWO-XGBoost**, combinent différentes techniques d'IA pour améliorer la précision des prévisions et offrir des outils potentiels pour la surveillance et la gestion des barrages. Ces études contribuent à la littérature sur l'utilisation de l'IA en sciences hydrauliques et peuvent être bénéfiques dans la conception et l'analyse des structures hydrauliques à des fins d'ingénierie.

**Tableau IV. 9.** Modèles Hybrides pour la modélisation du débit de fuite.

| Auteurs         | Année | Pays    | Inputs  | Output | Modèles          | Performances                                      |
|-----------------|-------|---------|---|--------|------------------|---|
| K. Zhang et al. | 2021  | China   | $H_{w_{amont}}$ $H_{w_{aval}}$<br>Temperature,<br>Precipitation<br>Vieillissant | PZ     | HGWO-<br>XGBoost | <b>RMSE= 1.0801</b><br><b>R<sup>2</sup>=0.966</b> |
| Rehamnia et al. | 2021  | Algérie | JJ, MM, PZ1 a PZ7,<br>CPE   | Q(L/S) | EKF-ANN          | <b>R= 0.9891,</b><br><b>RMSE= 0.2131</b>          |

## IV.9. Conclusion

En conclusion, les techniques d'intelligence artificielle (**IA**) ont été largement utilisées dans la modélisation du débit de fuite, offrant aux ingénieurs et aux chercheurs la possibilité de prédire avec précision ce débit et de développer des stratégies efficaces pour atténuer les fuites. Parmi les techniques couramment utilisées dans cette modélisation, on retrouve les modèles basés sur les réseaux de neurones artificiels (**ANN**), les modèles de régression, les modèles d'ensemble, l'**ANFIS** et d'autres modèles hybrides. Chaque technique présente ses propres forces et limites, et le choix de la méthode dépend de l'application spécifique et de la nature du problème à résoudre. Des recherches supplémentaires sont nécessaires afin d'explorer pleinement le potentiel de l'**IA** dans la modélisation du débit de fuite et de développer de nouvelles techniques qui pourraient améliorer la précision et l'efficacité du processus de modélisation.

---

**Chapitre V : Modélisation des Débits de Fuite par les Modèles à  
Base des Réseaux de Neurones Artificiels**

---

## V.1. Introduction

La prévision et la gestion précises du débit des fuites à travers les barrages sont essentielles pour assurer la stabilité et la sécurité de ces structures. Les méthodes traditionnelles de prévision de l'écoulement des fuites à travers les barrages sont basées sur des équations empiriques ou des modèles physiques, qui peuvent être longs et coûteux à développer et nécessitent souvent une collecte de données importante. Ces dernières années, les modèles de réseaux de neurone artificiels sont apparus comme une approche prometteuse pour prédire le débit de fuite en raison de leur capacité à modéliser des relations non linéaires complexes entre les variables d'entrée et de sortie. Dans ce chapitre, nous présentons les résultats obtenus à partir de trois modèles de réseaux neurone, à savoir le Multilayer Perceptron Neural Network (MLPNN), le Generalized Regression Neural Network (GRNN) et le Radial Basis Function Neural Network (RBFNN), dans la prédiction du débit de fuite à travers cinq barrages situés dans le nord de l'Algérie. L'ensemble de données utilisé dans cette étude comprend des variables d'entrée telles que la cote plane d'eau du barrage et les niveaux piézométriques dans déférant piézomètre. Lors de l'élaboration et de l'évaluation des modèles basés sur l'IA, il est de pratique courante de diviser la base de données en deux parties: une partie apprentissage et une partie validation. La phase d'apprentissage consiste à calibrer le modèle jusqu'à l'obtention des meilleurs paramètres. Une fois le modèle développé, il est évalué à l'aide de données de validation pour déterminer ses performances. Par conséquent, l'ensemble de données est divisé de manière aléatoire en deux parties: 70% des données pour l'apprentissage et 30% pour la validation.

Au total 12 modèles ayant différentes configurations ont été développés et comparés (**Tableau V.1**). Les douze modèles utilisent à la fois : (i) les levées piézométriques (PZ1 à PZ2), (ii) la côte du plan d'eau (CPE), et (iii) les composantes du calendrier grégorien qui sont : l'année (YY), le mois (MM), et le jour (DD). Il est important de noter que les modèles sont désignés par M1 à M12, ce qui signifie que dans la suite du chapitre, on trouvera les modèles MLPNN1, GRNN1, et RBFNN1 jusqu'à MLPNN12, GRNN12, et RBFNN12.

## V.2. Critères de validation des performances des modèles

La validation du modèle est une étape critique dans tout processus de modélisation, car elle garantit que le modèle représente avec précision le système réel qu'il est censé simuler. Il s'agit de comparer les valeurs prédites du modèle aux valeurs réelles observées pour déterminer la précision et la fiabilité du modèle. Une approche courante de la validation du modèle consiste à utiliser des critères de performance, qui sont des mesures statistiques qui mesurent la performance du modèle dans la réplique des données observées. Les critères de performance tels que le coefficient de corrélation R, l'erreur quadratique moyenne (RMSE), l'erreur absolue moyenne (MAE) et l'efficacité de Nash-Sutcliffe (NSE) sont utilisés dans cette étude pour quantifier la précision des modèles, et qui sont calculés par les formules suivantes :

$$R = \frac{\left(\Sigma((Q_m - Q_c) * (Q_m - Q_c))\right)}{\left(\sqrt{\Sigma(Q_m - Q_{\bar{m}})^2} * \sqrt{\Sigma(Q_c - Q_{\bar{c}})^2}\right)} \quad (V.01)$$

$$RMSE = \sqrt{\frac{\Sigma((Q_m - Q_c) * (Q_m - Q_c))}{n}} \quad (V.02)$$

$$MAE = \frac{\Sigma|Q_m - Q_c|}{n} \quad (V.03)$$

$$NSE = 1 - \frac{\left(\Sigma((Q_m - Q_c) * (Q_m - Q_c))\right)}{\Sigma((Q_m - Q_{\bar{m}}) * (Q_m - Q_{\bar{m}}))} \quad (V.04)$$

$Q_c$  représente le débit calculé,  $Q_m$  représente le débit mesuré,  $Q_{\bar{m}}$  et  $Q_{\bar{c}}$  sont les moyennes respectives des débits mesurés et calculés, alors que  $n$  est le nombre total d'échantillons.

### V.3. La Mise En Œuvre Des Modèles De Réseaux Neurone

Effectivement, les différents modèles utilisés en apprentissage automatique possèdent des paramètres différents à optimiser pendant la phase d'apprentissage. Les paramètres à optimiser dépendent du modèle et de la méthode d'optimisation utilisée. Les modèles MLPNN possèdent une couche d'entrée avec un nombre de neurones égal au nombre de variables d'entrées  $y$  compris les niveaux piézométriques dans déférant piézomètre (PZ) et le niveau d'eau (CPE), une couche cachée avec un nombre de neurones à déterminer (le nombre optimal varie en fonction du barrage et du modèle) et une couche de sortie avec une fonction d'activation linéaire. Les fonctions d'activation utilisées pour les neurones de la couche cachée est la fonction tangente sigmoïde et log sigmoïde. L'algorithme de rétropropagation de gradient est utilisé pour optimiser les paramètres pendant la phase d'apprentissage. Pour les réseaux RBFNN, ils ont une seule couche cachée avec une fonction d'activation appelée fonction noyau ou fonction gaussienne, et une couche de sortie avec une fonction d'activation linéaire. Le "Spread" de la fonction Gaussienne est un paramètre important qui peut être ajusté durant la phase d'apprentissage pour obtenir de meilleurs résultats. Le "Spread" contrôle la largeur des fonctions de base radiales, qui sont utilisées pour calculer la sortie du réseau. En général, le "Spread" est un paramètre qui varie entre 0.01 et 1 en fonction de la complexité du problème, et sa valeur optimale dépend du problème à résoudre. Si le "Spread" est trop petit, le modèle peut souffrir d'un Surapprentissage, tandis qu'un "Spread" trop grand peut entraîner une mauvaise généralisation. Le nombre de neurones dans la couche cachée est déterminé automatiquement pendant la phase d'apprentissage et peut être égal au nombre de données d'entrée. Les modèles de réseaux de neurone GRNN sont des modèles à passage unique sans apprentissage, avec quatre couches où le nombre de neurones dans chaque couche est déterminé automatiquement. Le paramètre « Spread » est variable pendant la phase d'apprentissage entre 0.1 et 1 au niveau de la deuxième couche. Le nombre de neurones dans la couche cachée est égal au nombre d'observations, et chaque neurone est affecté à une observation avec une zone d'influence dont le rayon est fonction du paramètre « Spread ».

## V.4. Résultats Obtenus par les modèles ANN: Barrage Bougous

La structure des modèles utilisées pour le barrage Bougous sont reportés dans le **Tableau V.1**. Nous avons au total 12 modèles. Les résultats obtenus sont présentés et discutés ci-après. Les résultats détaillés sont reportés dans le **Tableau V.2-4**.

**Tableau V. 1.** Structure des modèles utilisées pour le Barrage Bougous.

| N° | Modèles | Variables d'entrées (les inputs)              | Output    |
|----|---------|---|-----------|
| 01 | M1      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, CPE | $Q (L/S)$ |
| 02 | M2      | PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, CPE             | $Q (L/S)$ |
| 03 | M3      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6      | $Q (L/S)$ |
| 04 | M4      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, CPE      | $Q (L/S)$ |
| 05 | M5      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, CPE           | $Q (L/S)$ |
| 06 | M6      | YY, MM, DD, PZ1, PZ2, PZ3, CPE                | $Q (L/S)$ |
| 07 | M7      | YY, MM, DD, PZ1, PZ2, CPE                     | $Q (L/S)$ |
| 08 | M8      | YY, MM, DD, PZ1, CPE                          | $Q (L/S)$ |
| 09 | M9      | YY, MM, DD, PZ2, CPE                          | $Q (L/S)$ |
| 10 | M10     | YY, MM, DD, PZ3, CPE                          | $Q (L/S)$ |
| 11 | M11     | YY, MM, DD, PZ4, CPE                          | $Q (L/S)$ |
| 12 | M12     | YY, MM, DD, CPE                               | $Q (L/S)$ |

En analysant les résultats reportés dans le **Tableau V.2**, on peut conclure ce qui suit. En phase d'apprentissage, il est observé que tous les modèles ont donnés des valeurs élevées de R et de NSE qui variant de 0.942 à 0.997 et de 0.884 à 0.991 respectivement. Ces résultats indiquent un bon ajustement des données d'apprentissage. Les modèles MLPNN4 (R=0.996 et NSE=0.991), MLPNN5 (R=0.992 et NSE=0.983) et MLPNN7 (R=0.997 et NSE=0.993) ont enregistré les valeurs les plus élevées pour R et NSE, avec des valeurs proches de 1. Les valeurs des RMSE et MAE étaient généralement faibles pour tous les modèles, qui variant respectivement de 5.577 à 1.384 et de 3.772 à 0.987, indiquant des erreurs de prédiction relativement faibles. Il est également constaté que les entrées ont un effet significatif sur les performances des modèles. L'ajout des composantes du calendrier grégorien (YY, MM, DD) pour le modèle MLPNN2 a amélioré les valeurs de R et NSE, qui passent de 0.942 à 0.994 et de 0.884 à 0.988, avec un taux d'amélioration de 5.2% et 10.4%, respectivement, en comparaison avec le modèle MLPNN1. Il convient de noter que le modèle MLPNN2 est le seul à ne pas utiliser le calendrier grégorien parmi les 12 modèles et a enregistré les résultats les plus faibles. Cependant, il est important de souligner que les performances des modèles sur l'ensemble d'apprentissage ne garantissent pas leur capacité à généraliser sur de nouvelles données. Afin d'évaluer leur performance de généralisation, les modèles ont été testés sur un ensemble de validation distinct. Au cours de cette phase, les modèles ont été évalués sur des paires entrées-sorties qui n'ont pas été utilisées dans l'apprentissage, afin de mesurer leur capacité à prédire les sorties correspondantes en fonction des entrées inédites. Les résultats de la phase de validation révèlent des différences significatives par rapport aux résultats de l'apprentissage. Les valeurs de R et NSE obtenues lors de la validation sont généralement

inférieures à celles de l'apprentissage, tandis que les valeurs de RMSE et MAE sont généralement supérieures, indiquant des erreurs plus importantes dans les prédictions. En phase de validation, nous obtenons les meilleures valeurs de R (0.950) et NSE (0.891), ainsi que les valeurs les plus faibles des RMSE (5.397) et MAE (3.929), avec le modèle MLPNN7 est le modèle le plus efficace. En revanche, le MLPNN2 présente les performances les plus faibles avec des valeurs de R (0.826) et NSE (0.619). Par rapport aux autres modèles, notamment le MLPNN1 qui enregistre des valeurs de R (0.916) et NSE (0.834) avec une différence en pourcentage de 9.00% et 21.5%, respectivement. Cela confirme l'importance des entrées du calendrier grégorien dans le développement du modèle. D'autres modèles présentant des performances relativement bonnes pour la phase de validation : le MLPNN3 (R=0.943 et NSE=0.887), MLPNN6 (R=0.942 et NSE=0.884) et MLPNN8 (R=0.942 et NSE=0.854). Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents MLPNN modèles sont reportés dans la **Figure V.1**.

**Tableau V. 2.** Performances des différent modèles de MLPNN & barrage Bougous.

| Modèles | Training |       |       |       | Validation |       |        |       |
|---------|----------|-------|-------|-------|------------|-------|--------|-------|
|         | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE   | MAE   |
| MLPNN1  | 0.994    | 0.988 | 1.818 | 1.322 | 0.916      | 0.834 | 6.640  | 4.616 |
| MLPNN2  | 0.942    | 0.884 | 5.577 | 3.772 | 0.826      | 0.617 | 10.098 | 7.968 |
| MLPNN3  | 0.995    | 0.991 | 1.565 | 1.137 | 0.943      | 0.887 | 5.493  | 3.643 |
| MLPNN4  | 0.996    | 0.991 | 1.536 | 1.066 | 0.919      | 0.824 | 6.846  | 4.693 |
| MLPNN5  | 0.992    | 0.983 | 2.128 | 1.496 | 0.935      | 0.872 | 5.839  | 3.850 |
| MLPNN6  | 0.977    | 0.955 | 3.477 | 2.319 | 0.942      | 0.884 | 5.553  | 4.152 |
| MLPNN7  | 0.997    | 0.993 | 1.384 | 0.987 | 0.950      | 0.891 | 5.397  | 3.989 |
| MLPNN8  | 0.987    | 0.975 | 2.606 | 1.860 | 0.942      | 0.854 | 6.232  | 4.538 |
| MLPNN9  | 0.983    | 0.963 | 3.146 | 2.081 | 0.901      | 0.750 | 8.160  | 5.803 |
| MLPNN10 | 0.968    | 0.936 | 4.146 | 2.735 | 0.924      | 0.854 | 6.229  | 4.575 |
| MLPNN11 | 0.973    | 0.947 | 3.755 | 2.440 | 0.938      | 0.880 | 5.652  | 4.083 |
| MLPNN12 | 0.972    | 0.944 | 3.878 | 2.607 | 0.896      | 0.756 | 8.054  | 5.900 |

**Tableau V. 3.** Performances des différent modèles de RBFNN & barrage Bougous.

| Modèles | Training |       |       |       | Validation |       |        |       |
|---------|----------|-------|-------|-------|------------|-------|--------|-------|
|         | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE   | MAE   |
| RBFNN1  | 0.980    | 0.960 | 3.266 | 2.534 | 0.863      | 0.722 | 8.604  | 5.796 |
| RBFNN2  | 0.975    | 0.950 | 3.653 | 2.647 | 0.826      | 0.645 | 9.722  | 7.809 |
| RBFNN3  | 0.995    | 0.990 | 1.627 | 1.224 | 0.879      | 0.768 | 7.861  | 5.383 |
| RBFNN4  | 0.999    | 0.999 | 0.511 | 0.368 | 0.878      | 0.705 | 8.856  | 5.276 |
| RBFNN5  | 0.992    | 0.983 | 2.128 | 1.496 | 0.935      | 0.872 | 5.839  | 3.850 |
| RBFNN6  | 0.970    | 0.940 | 4.008 | 2.712 | 0.813      | 0.524 | 11.261 | 8.303 |
| RBFNN7  | 0.985    | 0.970 | 2.840 | 2.019 | 0.865      | 0.698 | 8.972  | 6.251 |
| RBFNN8  | 0.975    | 0.950 | 3.650 | 2.648 | 0.901      | 0.804 | 7.225  | 5.560 |
| RBFNN9  | 0.985    | 0.970 | 2.829 | 2.017 | 0.888      | 0.775 | 7.744  | 6.009 |
| RBFNN10 | 0.970    | 0.942 | 3.954 | 2.853 | 0.842      | 0.700 | 8.931  | 6.460 |
| RBFNN11 | 0.975    | 0.950 | 3.646 | 2.594 | 0.883      | 0.730 | 8.471  | 5.910 |
| RBFNN12 | 0.975    | 0.950 | 3.646 | 2.537 | 0.865      | 0.644 | 9.734  | 7.437 |

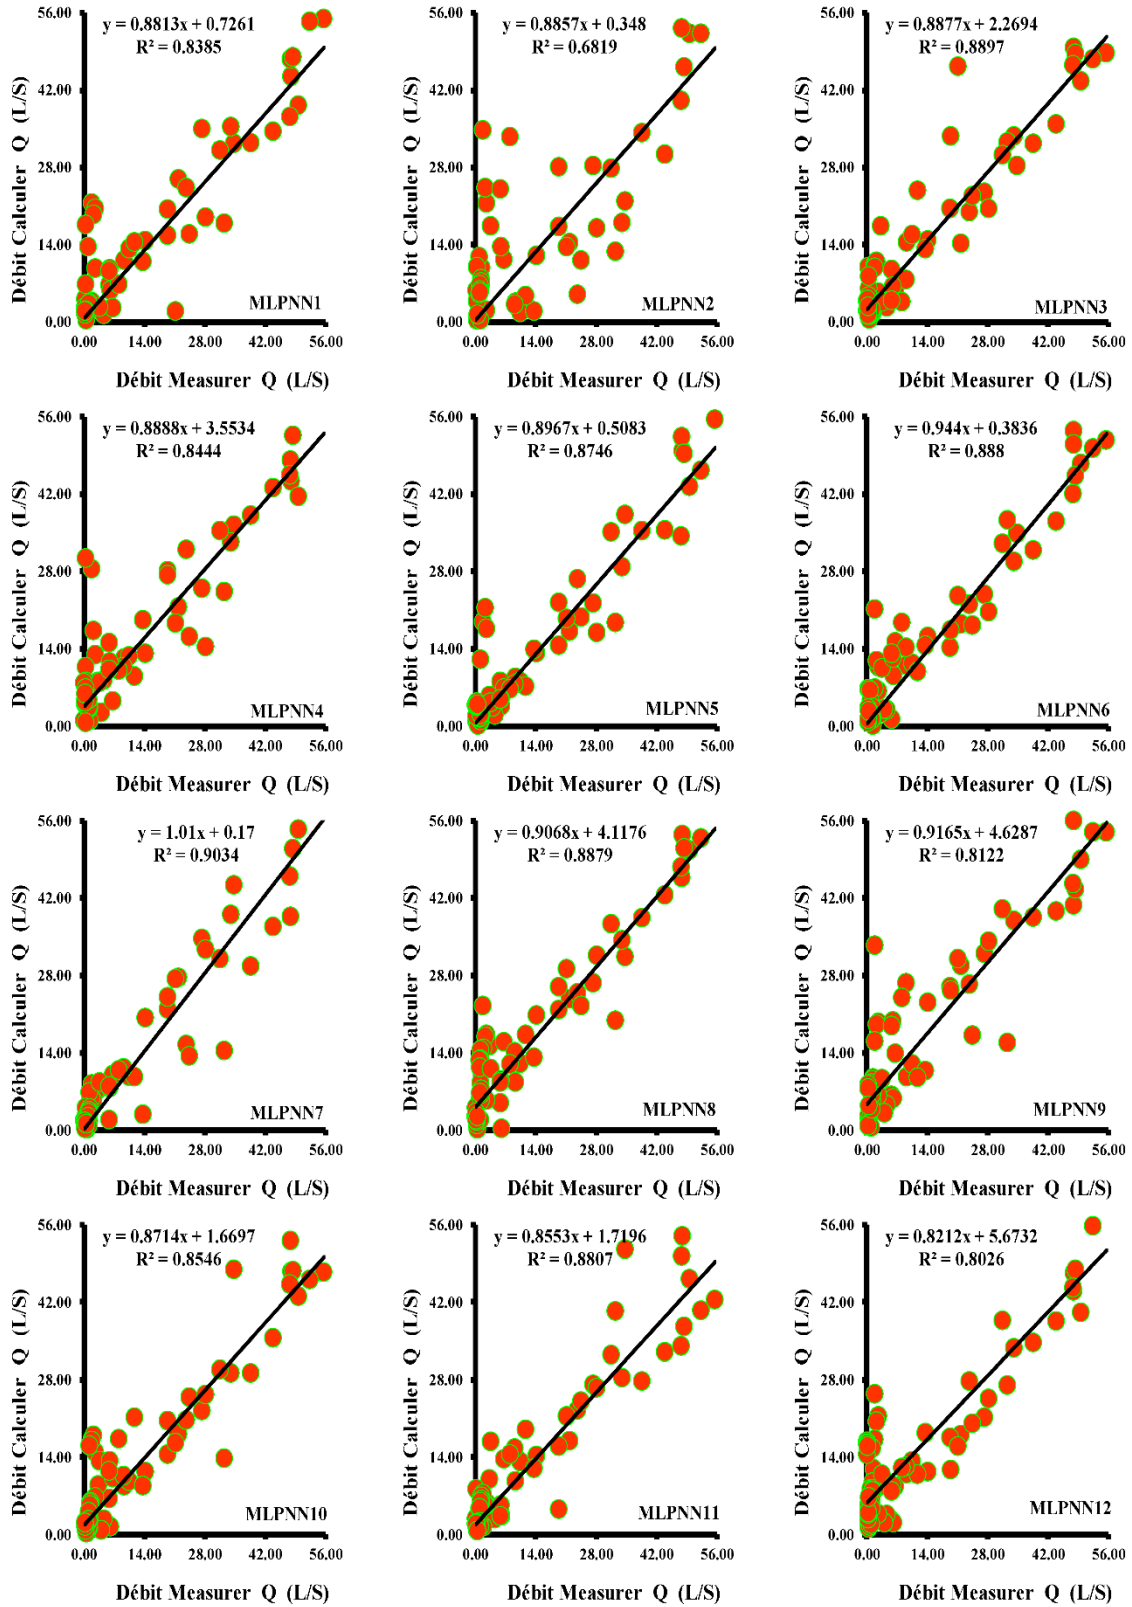


Figure V. 1. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents MLPNN modèles : barrage Bougous & phase de validation

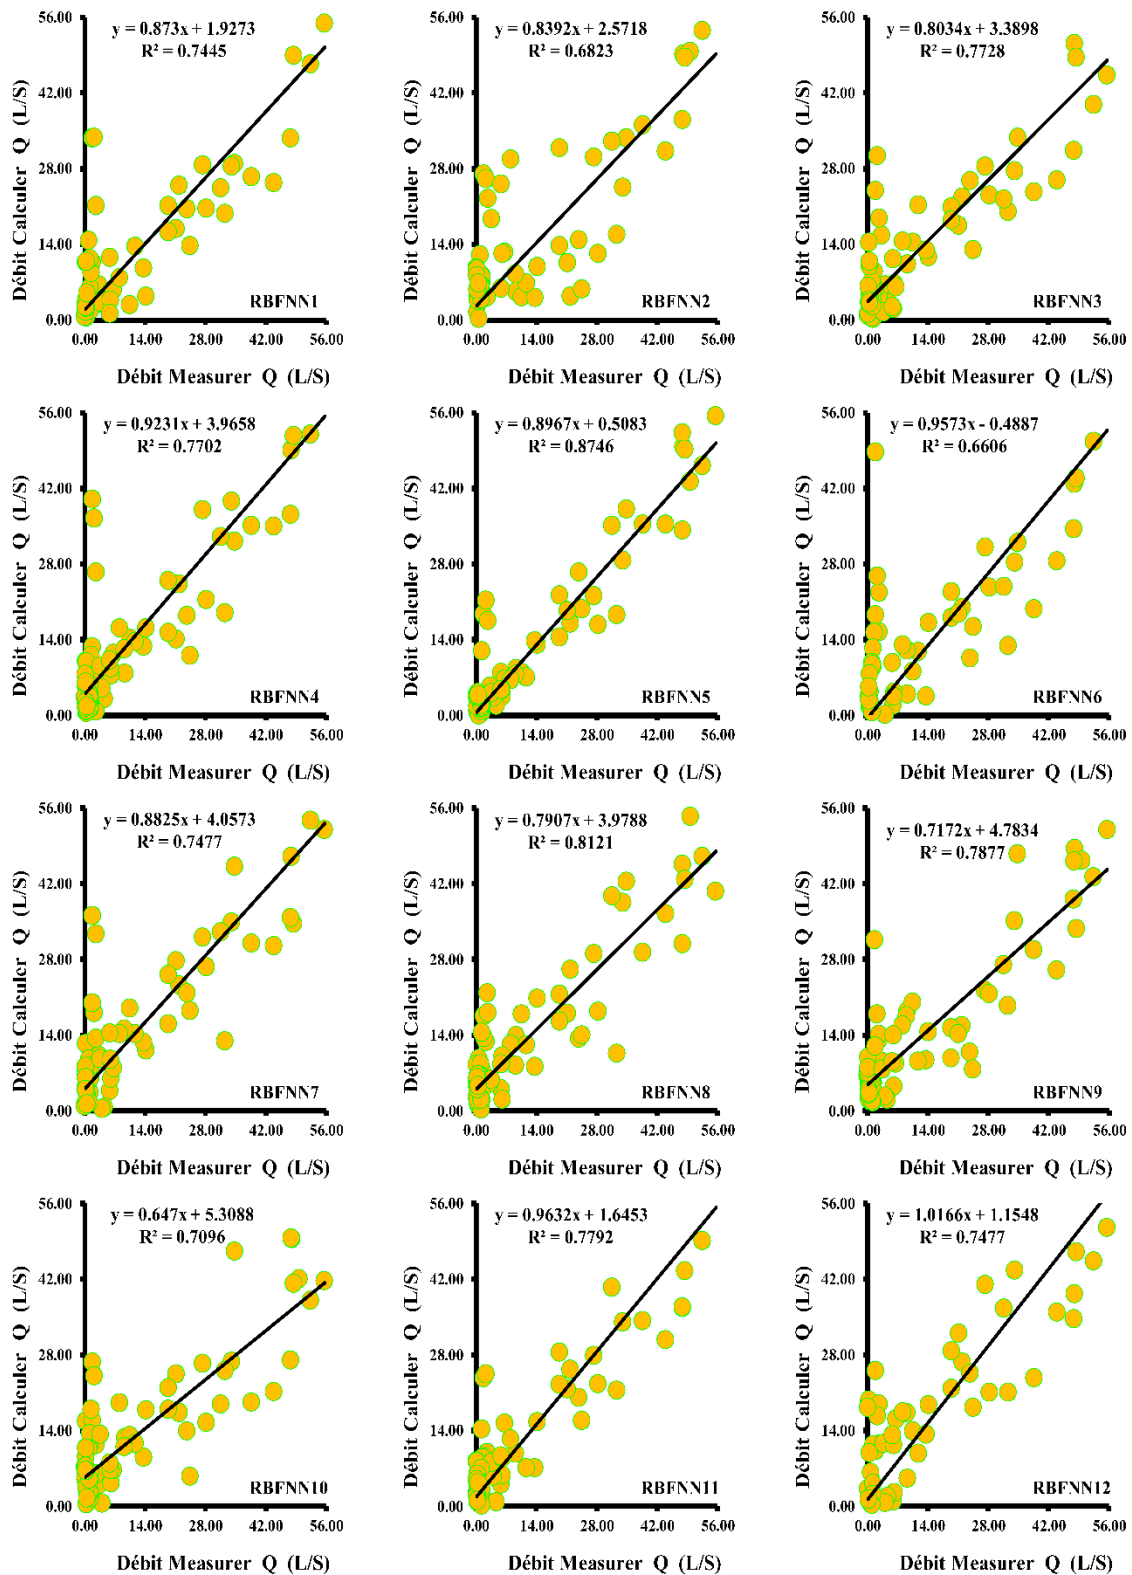


Figure V. 2. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents RBFNN modèles : barrage Bougous & phase de validation.

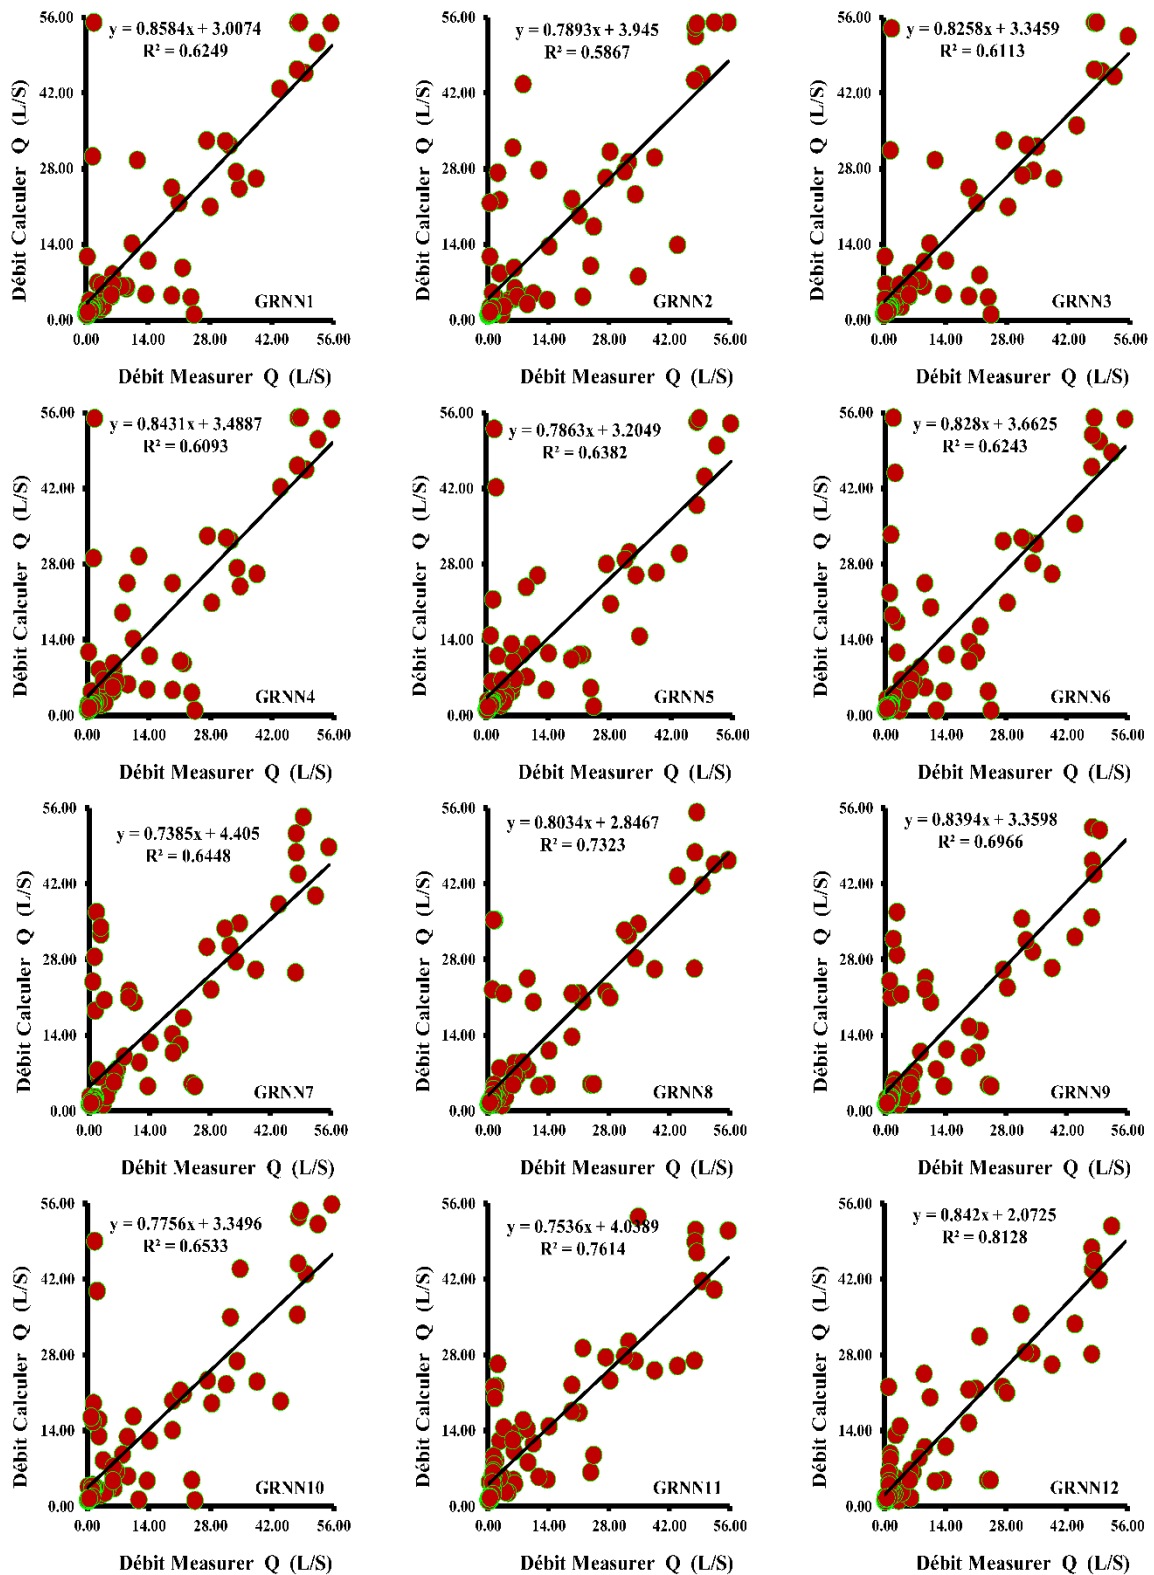


Figure V. 3. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents GRNN modèles : barrage Bougous & phase de validation.

Les résultats obtenus par les modèles RBFNN sont reportés dans le **Tableau V.3**. D'après les résultats, il semble y avoir une différence significative entre les modèles RBFNN et MLPNN. Les modèles RBFNN sont meilleures lors de la phase d'apprentissage, mais se détériorent considérablement lors de la phase de validation. Lors de la phase d'apprentissage, les modèles RBFNN ont produit des prévisions assez précises, avec des valeurs de RMSE et MAE relativement faibles, allant de 0.511L/s à 4.008L/s et de 0.368L/s à 3.954L/s respectivement. Le modèle RBFNN4 s'est distingué avec des valeurs de R et NSE parfaites de 0.999 et 0.999 respectivement, ainsi qu'avec les valeurs les plus faibles des RMSE et MAE (0.511 et 0.368). Les modèles RBFNN3 et RBFNN5 ont également obtenu de bons résultats avec des valeurs de R et NSE de 0.995 et 0.992, ainsi que 0.990 et 0.983 respectivement. Le modèle RBFNN1 était supérieur au RBFNN2, avec une amélioration de 0.5% et 1.0% pour R et NSE, ainsi que des améliorations de 38.70% et 11.30% pour RMSE et MAE respectivement. Ces résultats confirment l'importance de l'utilisation des composantes du calendrier grégorien (YY, MM, DD) dans les modèles RBFNN. Cependant, lors de la phase de validation, les performances des modèles RBFNN ont considérablement diminué par rapport à la phase d'apprentissage. Le modèle RBFNN5 a obtenu les meilleures performances avec des valeurs de R et NSE de 0.935 et 0.872, et des valeurs de RMSE et MAE de 5.839 et 3.850 respectivement. Il est à noter que le modèle RBFNN6 a réalisé les mauvaises performances avec des valeurs de RMSE et MAE de 11.261 et 8.303 respectivement. Ces résultats suggèrent que les modèles RBFNN ont du mal à généraliser efficacement. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents RBFNN modèles sont reportés dans la **Figure V.2**.

**Tableau V. 4.** Performances des différent modèles de GRNN & barrage Bougous.

| Modèles | Training |       |       |       | Validation |       |        |       |
|---------|----------|-------|-------|-------|------------|-------|--------|-------|
|         | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE   | MAE   |
| GRNN1   | 0.999    | 0.999 | 0.012 | 0.004 | 0.791      | 0.532 | 11.166 | 5.178 |
| GRNN2   | 0.999    | 0.999 | 0.012 | 0.004 | 0.791      | 0.532 | 11.166 | 5.178 |
| GRNN3   | 0.995    | 0.989 | 1.686 | 0.643 | 0.766      | 0.510 | 11.423 | 6.016 |
| GRNN4   | 0.999    | 0.999 | 0.044 | 0.006 | 0.782      | 0.530 | 11.180 | 5.332 |
| GRNN5   | 0.999    | 0.999 | 0.024 | 0.008 | 0.781      | 0.510 | 11.416 | 5.666 |
| GRNN6   | 0.999    | 0.998 | 0.754 | 0.324 | 0.799      | 0.602 | 10.287 | 5.638 |
| GRNN7   | 0.999    | 0.999 | 0.137 | 0.039 | 0.790      | 0.549 | 10.961 | 5.669 |
| GRNN8   | 0.999    | 0.998 | 0.676 | 0.370 | 0.803      | 0.626 | 9.982  | 5.741 |
| GRNN9   | 0.999    | 0.999 | 0.000 | 0.000 | 0.856      | 0.725 | 8.562  | 4.586 |
| GRNN10  | 0.999    | 0.998 | 0.677 | 0.342 | 0.835      | 0.660 | 9.514  | 5.564 |
| GRNN11  | 0.997    | 0.994 | 1.264 | 0.635 | 0.808      | 0.629 | 9.937  | 5.421 |
| GRNN12  | 0.988    | 0.973 | 2.713 | 1.647 | 0.873      | 0.757 | 8.037  | 5.367 |

En ce qui concerne les modèles GRNN (**Tableau V.4**), ils ont affiché des performances élevées lors de la phase d'apprentissage, avec six modèles sur douze obtenant des valeurs de R et NSE de l'ordre de 0.988 à 0.999 pour R et de 0.973 à 0.999 pour NSE. Les valeurs de RMSE variaient de 0.012 à 2.713 et les valeurs de MAE allaient de 0.004 à 1.647. Cependant, lors de la phase de validation, les performances des modèles GRNN ont également diminué de manière

significative. Le modèle GRNN12 a obtenu les meilleures performances avec des valeurs de R et NSE de 0.873 et 0.757, ainsi que des valeurs de RMSE et MAE de 8.037L/s et 5.367L/s, respectivement. Le modèle GRNN3 a donné les mauvaises performances avec des valeurs de R et NSE de 0.766 et 0.510, ainsi que des valeurs de RMSE et MAE de 11.423 L/s et 6.016 L/s respectivement. Ces résultats indiquent que les modèles GRNN sont plus performants pendant la phase d'apprentissage que les modèles MLPNN, alors qu'ils sont moins performant lors de la phase de validation (généralisation). Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents GRNN modèles sont reportés dans la **Figure V.3**.

En conclusion, les modèles RBFNN sont plus précis lors de la phase d'apprentissage, tandis que les modèles GRNN ont de bonnes performances pendant l'apprentissage mais se dégradent lors de la validation. Les modèles RBFNN8 et GRNN8 se sont révélés être les meilleurs parmi les modèles considérés, ce qui suggère que l'emplacement du piézomètre a un impact sur les performances des modèles dans la prédiction du débit de fuite. Nous avons comparé trois modèles ANN pour prédire les débits de fuite à travers une digue de barrage. Nous avons analysé les résultats en fonction de différentes combinaisons de variables d'entrée et des performances des modèles. En se basant sur ces résultats, nous pouvons tirer les conclusions suivantes :

- 1) Chaque approche a montré les meilleures performances dans une combinaison de variables d'entrée différent.
- 2) Dans les trois approches, nous avons remarqué que l'élimination des variables d'entrée relatives au calendrier grégorien entraîne une détérioration des performances dans la combinaison N°2 (P1, P2, P3, P4, P5, P6, CPE) par rapport à la combinaison N°1.
- 3) Dans les approches MLPNN et RBFNN, l'élimination de la variable d'entrée relative au niveau d'eau dans le réservoir améliore les performances dans (combinaison N°3 (YY, MM, DD, P1, P2, P3, P4, P5, P6)), tandis que dans l'approche GRNN, les performances se dégradent. De plus, en utilisant uniquement les variables d'entrée relatives au niveau d'eau dans le réservoir et au calendrier grégorien dans l'approche GRNN (combinaison N°12 (YY, MM, DD, CPE)), nous obtenons les meilleures performances.
- 4) L'utilisation d'un seul piézomètre dans les (combinaisons N°8, 9, 10, 11), avec une variation de son emplacement, montre une différence des performances.
- 5) La combinaison N°8 (YY, MM, DD, P1, CPE) a montré les meilleures performances parmi les quatre combinaisons dans les approches MLPNN et RBFNN.
- 6) Parmi les trois modèles ANN utilisées, l'approche MLPNN a clairement surpassé les autres en termes de performances.
- 7) Bien que l'approche GRNN ait été la meilleure lors de la phase d'apprentissage, elle a montré les mauvaises performances lors de la phase de validation, ce qui reflète son incapacité à la généralisation.
- 8) Les meilleurs modèles sont comparés en utilisant les figures Boxplot et Violinplot (**Figure V.4**) et par le diagram de Taylor (**Figure V.4**).

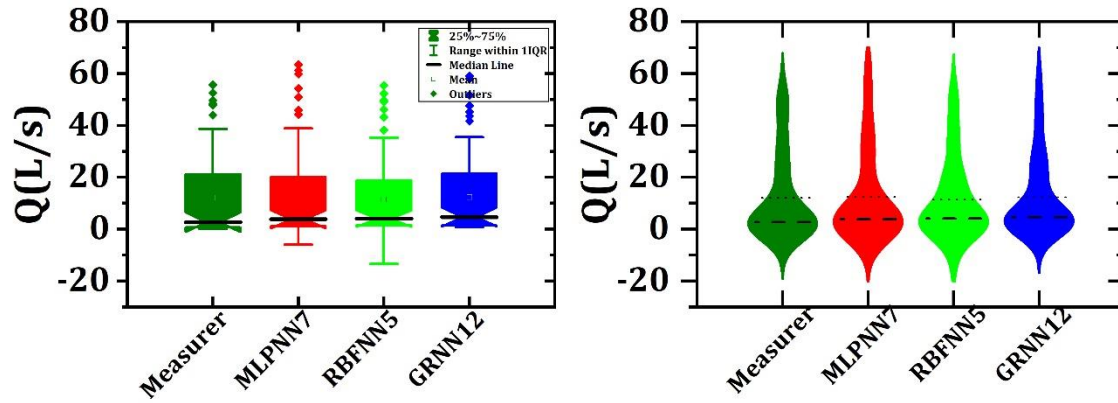


Figure V. 4. Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Bougouss




Figure V. 5. Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles : Barrage Bougouss.

### V.5. Résultats Obtenus par les modèles ANN: Barrage Cheurfas

Les structures des modèles utilisées pour le barrage Cheurfas sont reportés dans le **Tableau V.5**. Nous avons au total 12 modèles. Les résultats obtenus sont présentés et discutés ci-après. Les résultats détaillés sont reportés dans les **Tableau V.6-8**. Pour les modèles MLPNN (**Tableau V.6**), durant la phase d'apprentissage, les performances des modèles varient en fonction du nombre de variables d'entrée utilisées. Parmi les modèles MLPNN, les deux modèles MLPNN3 et MLPNN6 donnent les meilleures performances par rapport aux autres modèles. Ces modèles affichent des indicateurs statistiques élevés ( $R=0.988$ ,  $NSE=0.976$ ) suivi par le modèle MLPNN4 ( $R=0.986$ ,  $NSE=0.973$ ) et MLPNN5 ( $R=0.983$ ,  $NSE=0.966$ ) respectivement. Une conclusion préliminaire est que le nombre d'entrées peut augmenter la complexité des modèles, ce qui a un impact négatif sur les performances. De plus, la comparaison entre MLPNN1 et MLPNN2 met en évidence l'importance des composantes du calendrier grégorien dans l'amélioration des performances du MLPNN. En examinant les modèles MLPNN8, MLPNN9, MLPNN10 et MLPNN11, où le niveau d'eau dans le réservoir (CPE) et des piézomètres avec des emplacements différents ont été utilisés en tant qu'entrée, on

constate une faible différence de performance en termes des R et NSE. Le modèle MLPNN10 qui utilise le PZ3 était meilleur (R=0.948, NSE=0.897).

**Tableau V. 5.** Structure des modèles utilisées dans Barrage Cheurfas.

| N° | Modèles | Variables d'entrées (les inputs)              | Output  |
|----|---------|---|---------|
| 01 | M1      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, CPE | Q (L/S) |
| 02 | M2      | PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, CPE             | Q (L/S) |
| 03 | M3      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6      | Q (L/S) |
| 04 | M4      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, CPE      | Q (L/S) |
| 05 | M5      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, CPE           | Q (L/S) |
| 06 | M6      | YY, MM, DD, PZ1, PZ2, PZ3, CPE                | Q (L/S) |
| 07 | M7      | YY, MM, DD, PZ1, PZ2, CPE                     | Q (L/S) |
| 08 | M8      | YY, MM, DD, PZ1, CPE                          | Q (L/S) |
| 09 | M9      | YY, MM, DD, PZ2, CPE                          | Q (L/S) |
| 10 | M10     | YY, MM, DD, PZ3, CPE                          | Q (L/S) |
| 11 | M11     | YY, MM, DD, PZ4, CPE                          | Q (L/S) |
| 12 | M12     | YY, MM, DD, CPE                               | Q (L/S) |

**Tableau V. 6.** Performances des différent modèles de MLPNN & barrage Cheurfas.

| Models  | Training |       |       |       | Validation |       |       |       |
|---------|----------|-------|-------|-------|------------|-------|-------|-------|
|         | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE  | MAE   |
| MLPNN1  | 0.981    | 0.962 | 0.426 | 0.314 | 0.958      | 0.906 | 0.562 | 0.425 |
| MLPNN2  | 0.959    | 0.920 | 0.616 | 0.372 | 0.945      | 0.883 | 0.627 | 0.466 |
| MLPNN3  | 0.988    | 0.976 | 0.340 | 0.238 | 0.926      | 0.852 | 0.706 | 0.526 |
| MLPNN4  | 0.986    | 0.973 | 0.361 | 0.241 | 0.963      | 0.925 | 0.503 | 0.356 |
| MLPNN5  | 0.983    | 0.966 | 0.400 | 0.292 | 0.954      | 0.908 | 0.556 | 0.424 |
| MLPNN6  | 0.988    | 0.976 | 0.336 | 0.238 | 0.953      | 0.896 | 0.591 | 0.452 |
| MLPNN7  | 0.978    | 0.957 | 0.451 | 0.321 | 0.925      | 0.842 | 0.729 | 0.506 |
| MLPNN8  | 0.960    | 0.923 | 0.606 | 0.414 | 0.927      | 0.856 | 0.696 | 0.505 |
| MLPNN9  | 0.963    | 0.927 | 0.589 | 0.422 | 0.919      | 0.842 | 0.731 | 0.532 |
| MLPNN10 | 0.969    | 0.939 | 0.539 | 0.389 | 0.948      | 0.897 | 0.588 | 0.423 |
| MLPNN11 | 0.962    | 0.925 | 0.598 | 0.430 | 0.937      | 0.874 | 0.652 | 0.507 |
| MLPNN12 | 0.964    | 0.929 | 0.580 | 0.409 | 0.905      | 0.811 | 0.797 | 0.589 |

Dans la phase de validation, les résultats présentés dans le **Tableau V.5** étaient satisfaisantes, confirmant ainsi la capacité des modèles à généraliser. Le modèle MLPNN4 se distingue comme étant le plus performant (R=0.963, NSE=0.925, RMSE=0.503, MAE=0.356). La comparaison entre les modèles MLPNN1 et MLPNN2 confirme la supériorité de MLPNN1, soulignant l'importance du calendrier grégorien comme entrées et son impact positif sur les performances des modèles pour estimer le débit de fuite. De plus, parmi les quatre modèles MLPNN8 à MLPNN11, le modèle MLPNN10 se démarque comme étant le plus performant. Cela confirme l'effet de l'emplacement du piézomètre sur l'amélioration des performances de l'estimation du débit de fuite. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents MLPNN (barrage Cheurfas) sont reportés dans la **Figure V.6**.

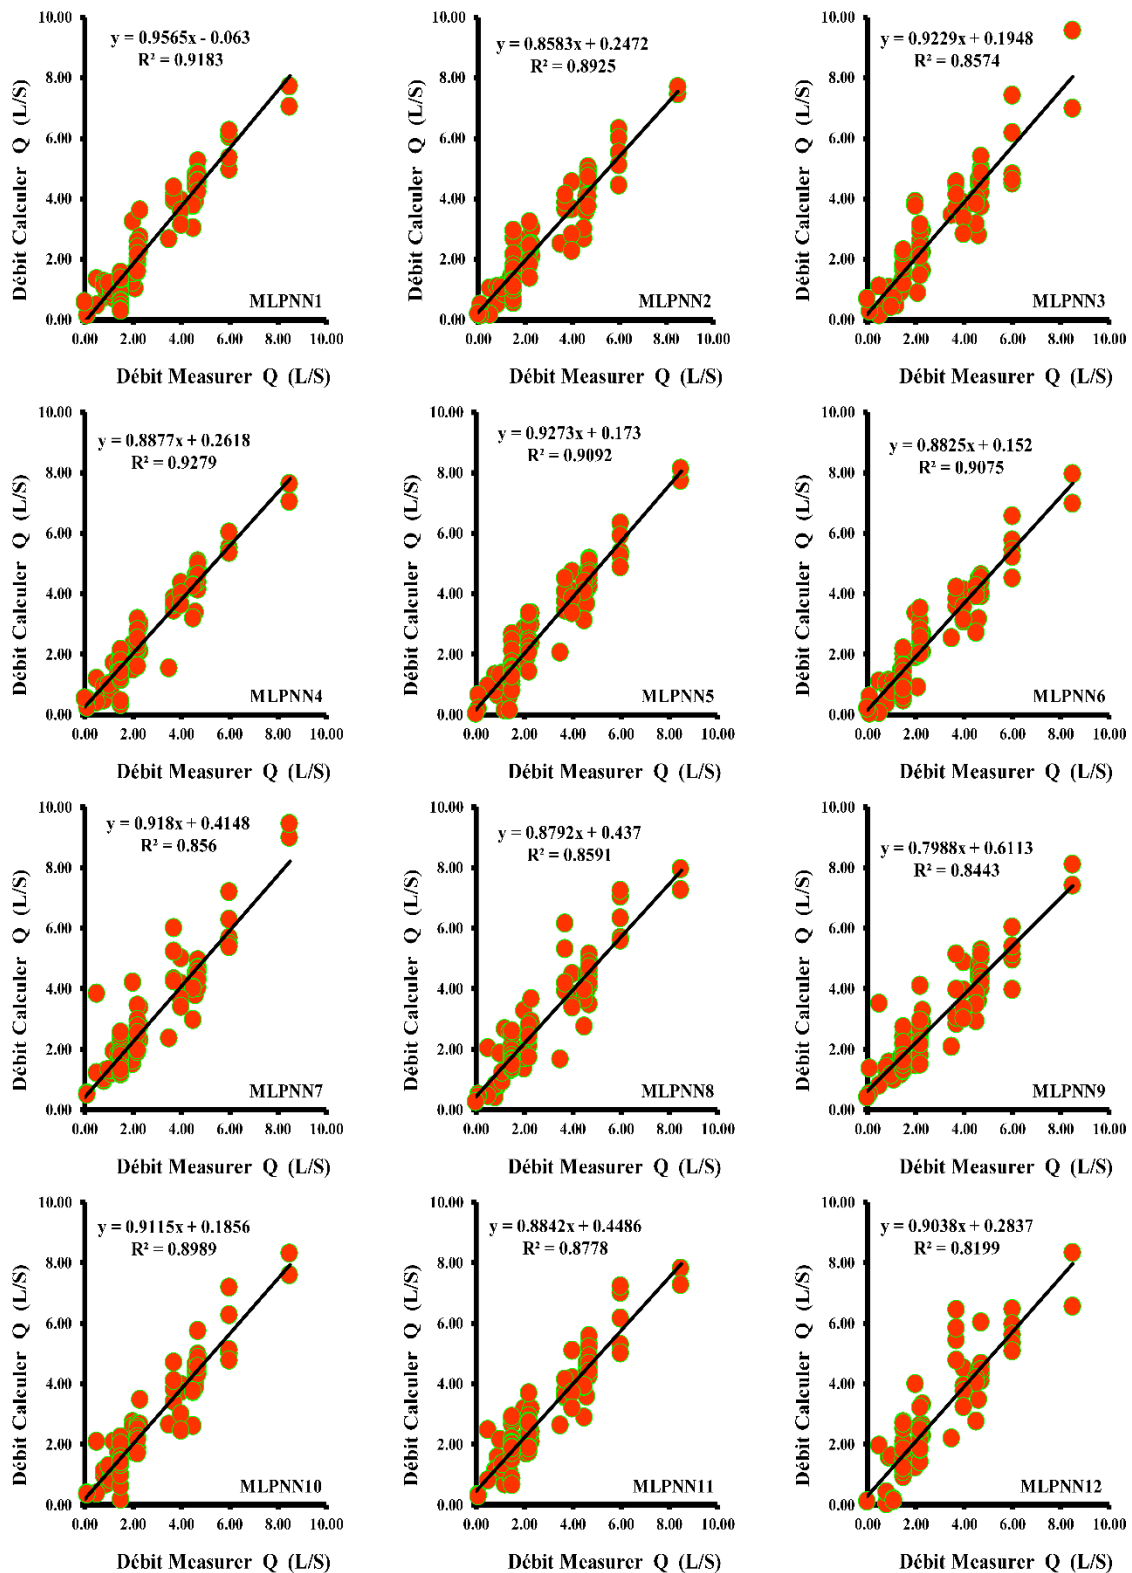


Figure V. 6. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents MLPNN modèles: barrage Cheufas & phase de validation.

**Tableau V. 7.** Performances des différents modèles de RBFNN & barrage Cheurfas.

| Models  | Training |       |       |       | Validation |       |       |       |
|---------|----------|-------|-------|-------|------------|-------|-------|-------|
|         | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE  | MAE   |
| RBFNN1  | 0.952    | 0.907 | 0.664 | 0.504 | 0.937      | 0.871 | 0.660 | 0.510 |
| RBFNN2  | 0.944    | 0.891 | 0.719 | 0.488 | 0.939      | 0.882 | 0.630 | 0.468 |
| RBFNN3  | 0.975    | 0.950 | 0.488 | 0.346 | 0.881      | 0.759 | 0.901 | 0.711 |
| RBFNN4  | 0.964    | 0.929 | 0.583 | 0.444 | 0.940      | 0.861 | 0.684 | 0.540 |
| RBFNN5  | 0.950    | 0.903 | 0.680 | 0.521 | 0.935      | 0.836 | 0.742 | 0.576 |
| RBFNN6  | 0.990    | 0.980 | 0.307 | 0.215 | 0.928      | 0.831 | 0.755 | 0.583 |
| RBFNN7  | 0.985    | 0.970 | 0.377 | 0.264 | 0.916      | 0.832 | 0.752 | 0.578 |
| RBFNN8  | 0.981    | 0.962 | 0.426 | 0.315 | 0.895      | 0.797 | 0.827 | 0.648 |
| RBFNN9  | 0.975    | 0.950 | 0.487 | 0.363 | 0.923      | 0.846 | 0.721 | 0.533 |
| RBFNN10 | 0.970    | 0.940 | 0.534 | 0.408 | 0.939      | 0.878 | 0.640 | 0.470 |
| RBFNN11 | 0.990    | 0.980 | 0.308 | 0.232 | 0.909      | 0.759 | 0.901 | 0.732 |
| RBFNN12 | 0.970    | 0.940 | 0.532 | 0.401 | 0.915      | 0.829 | 0.759 | 0.618 |

Les résultats obtenus à l'aide des modèles RBFNN (**Tableau V.7**) montrent une légère différence entre les modèles RBFNN et les modèles MLPNN dans la phase d'apprentissage. Cependant, la différence est plus marquée dans la phase de validation, indiquant que les modèles MLPNN sont plus efficaces dans la généralisation que les modèles RBFNN. Il convient de noter que les résultats de la phase d'apprentissage sont généralement plus précis que ceux de la phase de validation. Les évaluations du débit de fuite tout au long de la période d'apprentissage sont très bonnes, avec des valeurs RMSE comprises entre 0.3071/s et 0.719 1/s, et des valeurs MAE comprises entre 0.2151/s et 0.5211/s. Les meilleures performances sont obtenues avec les modèles RBFNN6 et RBFNN11, avec des valeurs de R et NSE de 0.990 et 0.980 respectivement, ainsi que des valeurs de RMSE et MAE de 0.3071/s et 0.2151/s, ce qui est très intéressant. Les modèles RBFNN7 et RBFNN3 suivent de près avec des valeurs de R de 0.985 et 0.970, et des valeurs de NSE de 0.975 et 0.950 respectivement. Le modèle RBFNN1 surpasse le RBFNN2 avec des améliorations de 0.80% et 1.60% en termes de R et NSE, respectivement, ainsi qu'une amélioration de 5.50% et 1.60% en termes de RMSE et MAE. Ces résultats confirment l'importance et l'utilité des composants du calendrier grégorien. En ce qui concerne l'emplacement du piézomètre, une différence de performance est observée entre les modèles RBFNN8 à RBFNN11, cependant, le modèle RBFNN11 affiche la meilleure performance, avec des valeurs de R=0.990 et NSE=0.980. Dans le modèle RBFNN12, qui utilise uniquement le niveau d'eau dans le réservoir et le calendrier grégorien comme entrées, de bonnes performances sont obtenues, avec des valeurs de R et NSE de 0.970 et 0.940, respectivement. Cela démontre l'effet de la présence de la CPE dans les entrées des modèles. La comparaison entre le modèle RBFNN12 et le modèle RBFNN3, qui ne contient pas les valeurs du niveau d'eau dans le réservoir révèle une très faible différence de performance.

Durant la phase de validation, nous avons remarqué que les résultats des modèles RBFNN prouvent leur capacité à généraliser, car il n'y a pas de différence significative entre la phase d'apprentissage et la validation. Le modèle RBFNN4 affiche les meilleures performances, avec des valeurs de R et NSE de 0.940 et 0.861, ainsi que des valeurs des RMSE et MAE de 0.6841/s et 0.5401/s, respectivement. Le modèle RBFNN10 suit de près, avec des valeurs de R

et NSE de 0,939 et 0,878. Il convient de noter que le modèle RBFNN3 présente les performances les plus faibles, avec des valeurs de  $R=0.881$ ,  $NSE=0.759$ ,  $RMSE=0.9011/s$  et  $MAE=0.7111/s$ . La différence entre ce modèle (RBFNN3) et les autres modèles réside dans le fait que les entrées ne contiennent pas les valeurs du niveau d'eau dans le réservoir (CPE). En comparant le modèle RBFNN12, qui ne contient pas de mesures de pression mais contient les valeurs du niveau d'eau dans le réservoir avec le calendrier grégorien, avec le modèle RBFNN3, nous constatons une supériorité au profit du modèle RBFNN12 en termes de  $R$  et  $NSE$ , avec des améliorations de 3.40% et 7.00% respectivement. Des différences entre les modèles RBFNN8 à RBFNN11 persiste, mais la meilleure performance en phase de validation est celle du modèle RBFNN10, avec  $R=0.939$  et  $NSE=0.878$ . Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents RBFNN (barrage Cheurfas) sont reportés dans la **Figure V.7**.

**Tableau V. 8.** Performances des différents modèles de GRNN & barrage Cheurfas.

| Models | Training |       |       |       | Validation |       |       |       |
|--------|----------|-------|-------|-------|------------|-------|-------|-------|
|        | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE  | MAE   |
| GRNN1  | 0.985    | 0.969 | 0.381 | 0.222 | 0.942      | 0.873 | 0.653 | 0.480 |
| GRNN2  | 0.965    | 0.932 | 0.570 | 0.263 | 0.953      | 0.892 | 0.604 | 0.430 |
| GRNN3  | 0.945    | 0.889 | 0.727 | 0.508 | 0.867      | 0.743 | 0.931 | 0.727 |
| GRNN4  | 0.984    | 0.967 | 0.394 | 0.235 | 0.939      | 0.868 | 0.666 | 0.491 |
| GRNN5  | 0.981    | 0.960 | 0.435 | 0.281 | 0.944      | 0.875 | 0.648 | 0.482 |
| GRNN6  | 0.980    | 0.958 | 0.446 | 0.296 | 0.944      | 0.876 | 0.645 | 0.479 |
| GRNN7  | 0.972    | 0.940 | 0.532 | 0.356 | 0.908      | 0.821 | 0.776 | 0.540 |
| GRNN8  | 0.982    | 0.961 | 0.429 | 0.265 | 0.887      | 0.785 | 0.851 | 0.565 |
| GRNN9  | 0.972    | 0.940 | 0.532 | 0.356 | 0.908      | 0.821 | 0.777 | 0.541 |
| GRNN10 | 0.990    | 0.980 | 0.311 | 0.195 | 0.944      | 0.878 | 0.640 | 0.464 |
| GRNN11 | 0.984    | 0.967 | 0.396 | 0.226 | 0.939      | 0.865 | 0.674 | 0.484 |
| GRNN12 | 0.982    | 0.961 | 0.429 | 0.265 | 0.887      | 0.785 | 0.851 | 0.565 |

Pour les modèles GRNN (**Tableau V.8**), les meilleurs résultats en phase de validation sont obtenus avec le modèle GRNN2, avec des valeurs de  $R=0.953$ ,  $NSE=0.892$ ,  $RMSE=0.6041/s$  et  $MAE=0.4301/s$ . Cela est différent des résultats précédents car le modèle GRNN2 surpasse le modèle GRNN1, qui inclut le calendrier grégorien parmi les entrées, avec des améliorations de 1.10%, 1.90%, 4.90% et 5.00%. Il convient de noter que le modèle GRNN3 affiche les performances les plus faibles, avec  $R=0.867$ ,  $NSE=0.743$ ,  $RMSE=0.931$  l/s et  $MAE=0.7271/s$ . Cela prouve l'effet positif d'inclure les valeurs du niveau d'eau dans le réservoir, car on observe la supériorité du modèle GRNN12 par rapport au modèle GRNN3, avec des améliorations de performances de 2.00%, 4.20%, 8.00% et 16.20% en termes de  $R$ ,  $NSE$ ,  $RMSE$  et  $MAE$ , respectivement. Il est important de se référer aux quatre modèles GRNN8 à GRNN11, là où, le modèle GRNN10 nous offre toujours les meilleures performances (GRNN10 avec  $R=0.944$ ,  $NSE=0.878$ ). Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents GRNN (barrage Cheurfas) sont reportés dans la **Figure V.8**.

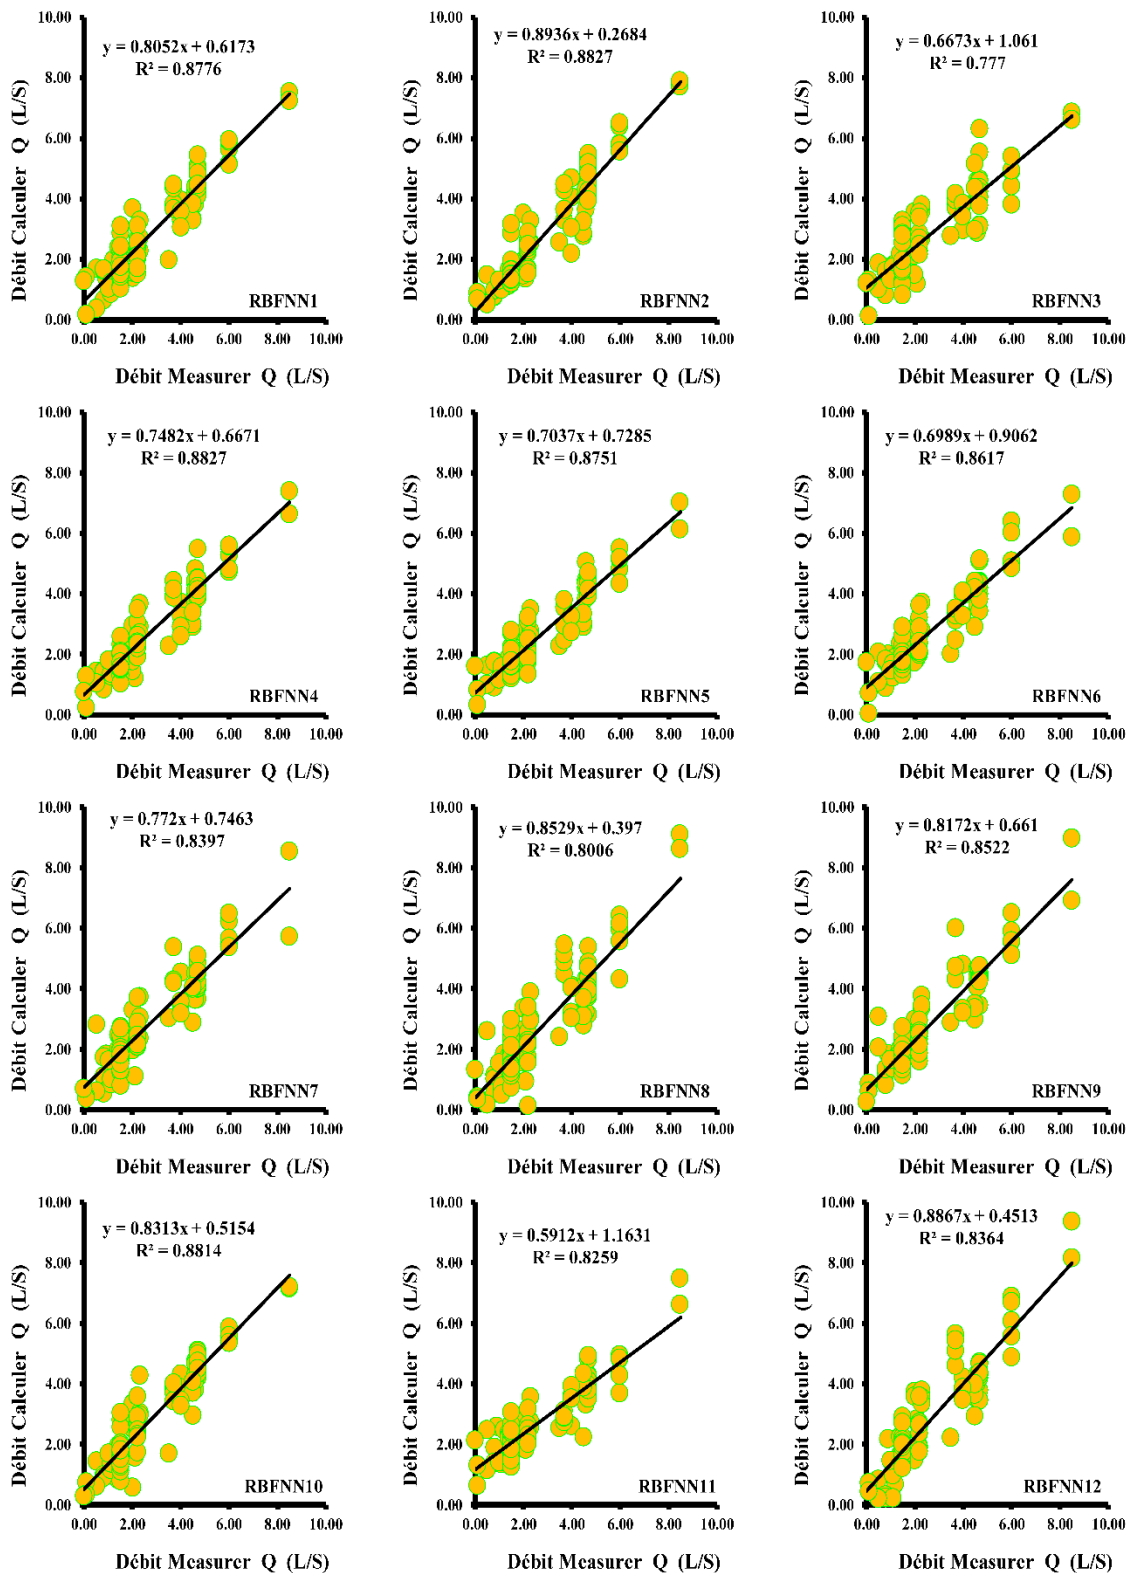


Figure V. 7. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents RBFNN modèles: barrage Cheurfas & phase de validation.

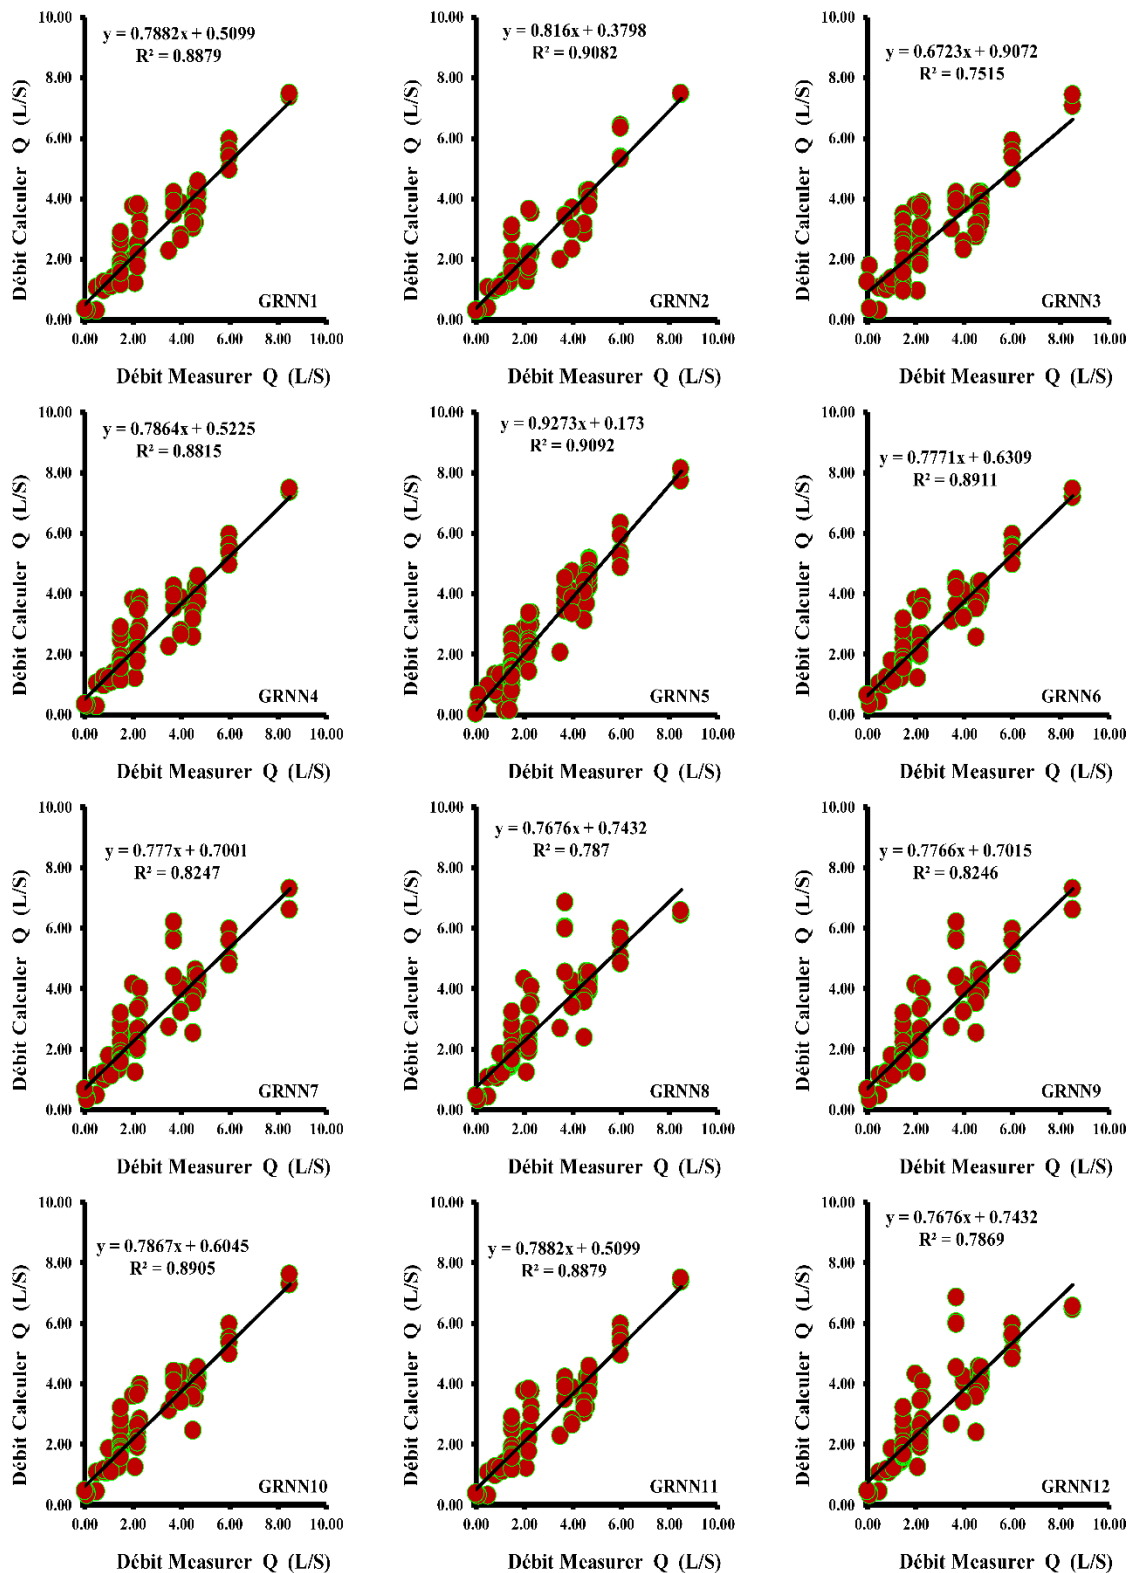


Figure V. 8. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents GRNN modèles: barrage Cheurfas & phase de validation.

En analysant les résultats et en comparant les performances des trois modèles précédents appliquer pour prédire les débits de fuites à travers le barrage de Cheurfas Mascara, nous pouvons tirer les conclusions suivantes:

- 1) Les modèles MLPNN et RBFNN ont montré les meilleures performances dans la combinaison N°4, tandis que l'approche GRNN a montré les meilleures performances dans la combinaison N°2 après l'élimination des variables du calendrier grégorien.
- 2) L'élimination des variables d'entrée du calendrier grégorien dans la combinaison N°2 améliore les performances à la fois pour RBFNN et GRNN, mais détériore les performances des modèles MLPNN.
- 3) Lorsque les variables d'entrée relatives au niveau d'eau dans le réservoir du barrage (CPE) sont éliminées (combinaison N°3), les performances se détériorent considérablement dans les trois approches.
- 4) Dans les groupes comprenant un seul piézomètre (combinaison N°8, 9, 10, 11), on observe une variation des performances en fonction du piézomètre utilisé, et la combinaison N°10 a montré les meilleures performances dans les trois approches.
- 5) Bien que tous les modèles aient montré de bonnes performances, MLPNN a présenté les meilleures performances.
- 6) Les meilleurs modèles sont comparés en utilisant les figures Boxplot et Violinplot (Figure V.9) et par le diagramme de Taylor (Figure V.10).

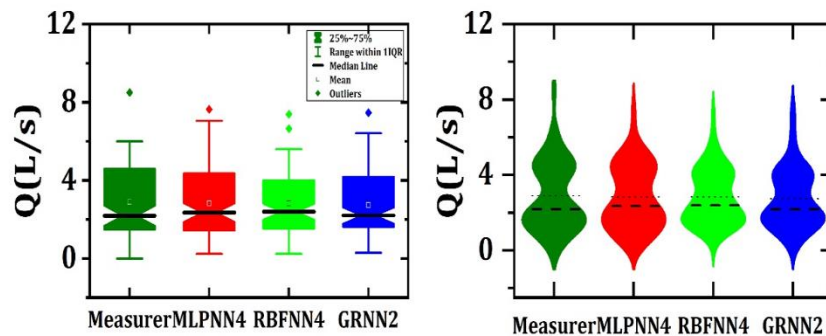


Figure V. 9. Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Cheurfas.




Figure V. 10. Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles : Barrage Cheurfas.

### V.6. Résultats Obtenus par les modèles ANN: Barrage Zit Emba

Les structures des modèles utilisées pour le barrage Zit Emba sont reportés dans le **Tableau V.9**. Nous avons au total 12 modèles. Les résultats obtenus sont présentés et discutés ci-après. Les résultats détaillés sont reportés dans les **Tableau V.10-12**.

**Tableau V. 9.** Structure des modèles utilisées dans Barrage Zit Emba.

| N° | Modèles | Variables d'entrées (les inputs)                             | Output    |
|----|---------|--|-----------|
| 01 | M1      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, PZ7, PZ8, PZ9, CPE | Q (L/Min) |
| 02 | M2      | PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, PZ7, PZ8, PZ9, CPE             | Q (L/Min) |
| 03 | M3      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, PZ7, PZ8, PZ9      | Q (L/Min) |
| 04 | M4      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, PZ7, PZ8, CPE      | Q (L/Min) |
| 05 | M5      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, PZ7, CPE           | Q (L/Min) |
| 06 | M6      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, CPE                | Q (L/Min) |
| 07 | M7      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, CPE                     | Q (L/Min) |
| 08 | M8      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, CPE                          | Q (L/Min) |
| 09 | M9      | YY, MM, DD, PZ1, PZ2, PZ3, CPE                               | Q (L/Min) |
| 10 | M10     | YY, MM, DD, PZ1, PZ2, CPE                                    | Q (L/Min) |
| 11 | M11     | YY, MM, DD, PZ1, CPE   | Q (L/Min) |
| 12 | M12     | YY, MM, DD, CPE  | Q (L/Min) |

**Tableau V. 10.** Performances des différent modèles de MLPNN & barrage Zit Emba.

| Modèles | Training |       |       |       | Validation |       |       |       |
|---------|----------|-------|-------|-------|------------|-------|-------|-------|
|         | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE  | MAE   |
| MLPNN1  | 0.834    | 0.695 | 0.854 | 0.646 | 0.851      | 0.705 | 0.939 | 0.761 |
| MLPNN2  | 0.883    | 0.779 | 0.728 | 0.550 | 0.861      | 0.729 | 0.901 | 0.705 |
| MLPNN3  | 0.922    | 0.846 | 0.608 | 0.472 | 0.845      | 0.702 | 0.945 | 0.745 |
| MLPNN4  | 0.949    | 0.899 | 0.491 | 0.375 | 0.851      | 0.617 | 1.071 | 0.855 |
| MLPNN5  | 0.901    | 0.812 | 0.671 | 0.510 | 0.852      | 0.661 | 1.008 | 0.808 |
| MLPNN6  | 0.911    | 0.827 | 0.643 | 0.492 | 0.838      | 0.624 | 1.061 | 0.878 |
| MLPNN7  | 0.918    | 0.841 | 0.617 | 0.468 | 0.856      | 0.684 | 0.973 | 0.783 |
| MLPNN8  | 0.901    | 0.811 | 0.672 | 0.503 | 0.842      | 0.674 | 0.988 | 0.801 |
| MLPNN9  | 0.886    | 0.784 | 0.720 | 0.539 | 0.826      | 0.411 | 1.327 | 1.036 |
| MLPNN10 | 0.922    | 0.850 | 0.600 | 0.451 | 0.821      | 0.520 | 1.199 | 0.984 |
| MLPNN11 | 0.890    | 0.792 | 0.706 | 0.529 | 0.820      | 0.617 | 1.070 | 0.873 |
| MLPNN12 | 0.841    | 0.707 | 0.837 | 0.633 | 0.834      | 0.684 | 0.972 | 0.796 |

Pour les modèles MLPNN (**Tableau V.10**), Pour la phase d'apprentissage, en examinant les résultats, le MLPNN4 a donné les valeurs les plus élevées de R (0.949) et de NSE (0.899), ce qui indique une forte corrélation entre les valeurs prédites et les valeurs réelles, ainsi qu'une grande efficacité à simuler le débit de fuite. De plus, MLPNN4 a obtenu les valeurs les plus faibles de RMSE (0.491) et de MAE (0.375), ce qui signifie la plus petite différence entre les valeurs prédites et les valeurs mesurées. D'autre part, le MLPNN1 a donné les performances les plus faible lors de la phase d'apprentissage. Il a donné des valeurs de R (0.834) et de NSE (0.695), ce qui indique une corrélation et une efficacité plus faibles par rapport aux autres modèles. De plus, MLPNN9 a affiché des valeurs plus élevées de RMSE (0.854) et de MAE (0.646), ce qui suggère de plus grandes erreurs de prédiction. En phase de validation, des critères similaires peuvent être utilisés pour déterminer les modèles supérieurs et inférieurs.

MLPNN2 a donné les valeurs les plus élevées de R (0.861) et de NSE (0.729), démontrant une forte corrélation et une efficacité élevée dans l'ensemble de validation. Il a également donné des valeurs relativement plus faibles de RMSE (0.901) et de MAE (0.705), ce qui implique de plus petites erreurs de prédiction. En revanche, MLPNN9 a également donné les performances les plus médiocres lors de la phase de validation. Il a donné la valeur la plus basse de R (0.826) et de NSE (0.411), ce qui indique une corrélation et une efficacité plus faibles dans la capture des données de validation. De plus, MLPNN9 a affiché les valeurs les plus élevées de RMSE (1.327) et de MAE (1.036), ce qui suggère de plus grandes erreurs de prédiction.

En ce qui concerne l'influence des diverses variables d'entrée sur les performances des modèles, on peut observer que, par exemple, le MLPNN4, qui a exclu le piézomètre PZ9, a obtenu les meilleures performances lors de la phase d'apprentissage, ce qui suggère que PZ9 pourrait ne pas avoir un impact significatif sur les capacités prédictives du modèle pour ce cas spécifique. De même, pour le MLPNN2, qui a exclu les composantes du calendrier grégorien (AA, MM, JJ), a donné de bon performances dans les deux phases. L'inverse pour le MLPNN3, pour lequel nous avons exclu la CPE (niveau d'eau), ses performances se sont dégradé en phase de validation, indiquant un effet positif de la CPE parmi toute les variables d'entrée. En résumé, les modèles MLPNN ont présenté des performances variables lors des phases d'apprentissage et de validation. MLPNN4 et MLPNN2 se sont révélés être les modèles supérieurs, démontrant une corrélation plus forte, une plus grande efficacité et de plus petites erreurs de prédiction. MLPNN9 a constamment affiché de moins bonnes performances dans les deux phases. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents MLPNN (barrage Zit Emba) sont reportés dans la **Figure V.11**.

Les performances des différents modèles RBFNN lors des phases d'apprentissage et de validation sont illustrés dans le **Tableau V.11**. Pour la phase d'apprentissage. Le modèle RBFNN4 a donné les valeurs les plus élevées de R (0.934) et de NSE (0.872), ce qui indique une forte corrélation et une efficacité élevée pour capturer les données d'apprentissage. De plus, RBFNN4 a obtenu les valeurs les plus faibles de RMSE (0.553) et de MAE (0.421), ce qui suggère de plus petites erreurs de prédiction. Par ailleurs, les modèles RBFNN1, RBFNN2, RBFNN3, RBFNN5, RBFNN6 et RBFNN8 ont démontré des performances presque similaires et relativement bonnes lors de la phase d'apprentissage. Ils ont obtenu des valeurs acceptables pour R (0.917 à 0.927) et NSE (0.841 à 0.860), ce qui témoigne d'une corrélation et d'une efficacité relativement élevées. De plus, ces modèles ont affiché des valeurs de RMSE (0.617 à 0.576) et de MAE (0.459 à 0.444). En revanche, le modèle RBFNN12 a présenté les performances les plus médiocres avec les valeurs les plus faibles avec les mesures suivantes: R=0.814 et NSE=0.662, ce qui indique une corrélation et une efficacité plus faibles. De plus, il a enregistré les valeurs d'erreur les plus élevées avec un RMSE de 0.899 et un MAE de 0.672, suggérant ainsi des erreurs de prédiction plus importantes.

En à la phase de validation, le RBFNN5 a donné les valeurs les plus élevés de R (0.851) et de NSE (0.685), ce qui indique une forte corrélation et une efficacité élevée pour simuler les données de validation. Il a également donné des valeurs relativement plus faibles de RMSE (0.972) et de MAE (0.759), ce qui implique de plus petites erreurs de prédiction. Inversement,

le RBFNN8 a également donné les performances les plus médiocres lors de la phase de validation. Il a donné la valeur la plus basse de R (0.828) et un NSE négatif (-0,107), ce qui indique une corrélation et une efficacité très faibles pour capturer les données de validation. De plus, RBFNN8 a affiché les valeurs les plus élevées de RMSE (1.820) et de MAE (1.310), ce qui suggère de plus grandes erreurs de prédiction. En comparaison avec les modèles MLPNN, les modèles RBFNN présentent différentes performances. Alors que certains modèles RBFNN, comme RBFNN4 et RBFNN5, performant bien à la fois lors des phases d'apprentissage et de validation, d'autres, comme RBFNN8 était faible. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents RBFNN (barrage Zit Emba) sont reportés dans la **Figure V.12**.

Les performances de différents modèles GRNN lors des phases d'apprentissage et de validation ont été présentées dans le **Tableau V.12**. En phase d'apprentissage, le modèle GRNN12 a donné les valeurs les plus élevées de R (0.965) et de NSE (0.926), ce qui indique une forte corrélation et une efficacité élevée pour capturer les données d'apprentissage. De plus, GRNN12 a donné les valeurs les plus faibles de RMSE (0.421) et de MAE (0.284), ce qui suggère de plus petites erreurs de prédiction. D'autre part, GRNN3 a donné des performances relativement médiocres lors de la phase d'apprentissage. Il a obtenu les valeurs les plus basses de R (0.895) et de NSE (0.794), ce qui indique une corrélation et une efficacité plus faibles. De plus, le GRNN3 a donné les valeurs les plus élevées de RMSE (0.703) et de MAE (0.507), ce qui suggère de plus grandes erreurs de prédiction. Les modèles GRNN9 et GRNN11 ont présenté des performances similaires, avec des valeurs de R de 0.962 et 0.963 respectivement, ainsi que des valeurs de NSE de 0.920 et 0.922, respectivement. De plus, ces modèles ont affiché des valeurs de RMSE de l'ordre de 0.438 et 0.431, respectivement. Ces résultats suggèrent une faible erreur de prédiction pour le débit de fuite.

En phase de validation, le GRNN3 a donné les valeurs les plus élevées de R (0.855) et de NSE (0.706). Il a également assuré des valeurs plus faibles de RMSE (0.938) et de MAE (0.796), ce qui implique de plus petites erreurs de prédiction. Inversement, le GRNN12 a donné les performances les plus médiocres. Il a donné la valeur la plus basse de R (0.830) et de NSE (0.647). De plus, le GRNN12 a affiché les valeurs les plus élevées de RMSE (1.028) et de MAE (0.865), ce qui suggère de plus grandes erreurs de prédiction. En comparaison avec les modèles MLPNN et RBFNN discutés précédemment, les modèles GRNN présentent des performances différentes. Le GRNN12 s'est révélé être le modèle supérieur, avec une forte corrélation, une haute efficacité et de petites erreurs de prédiction. GRNN3 a été faible à la fois lors des phases d'apprentissage et de validation. Pendant la phase d'apprentissage, le modèle GRNN12 s'est révélé être le meilleur, avec une corrélation élevée, une efficacité notable et de faibles erreurs de prédiction. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents GRNN (barrage Zit Emba) sont reportés dans la **Figure V.13**.

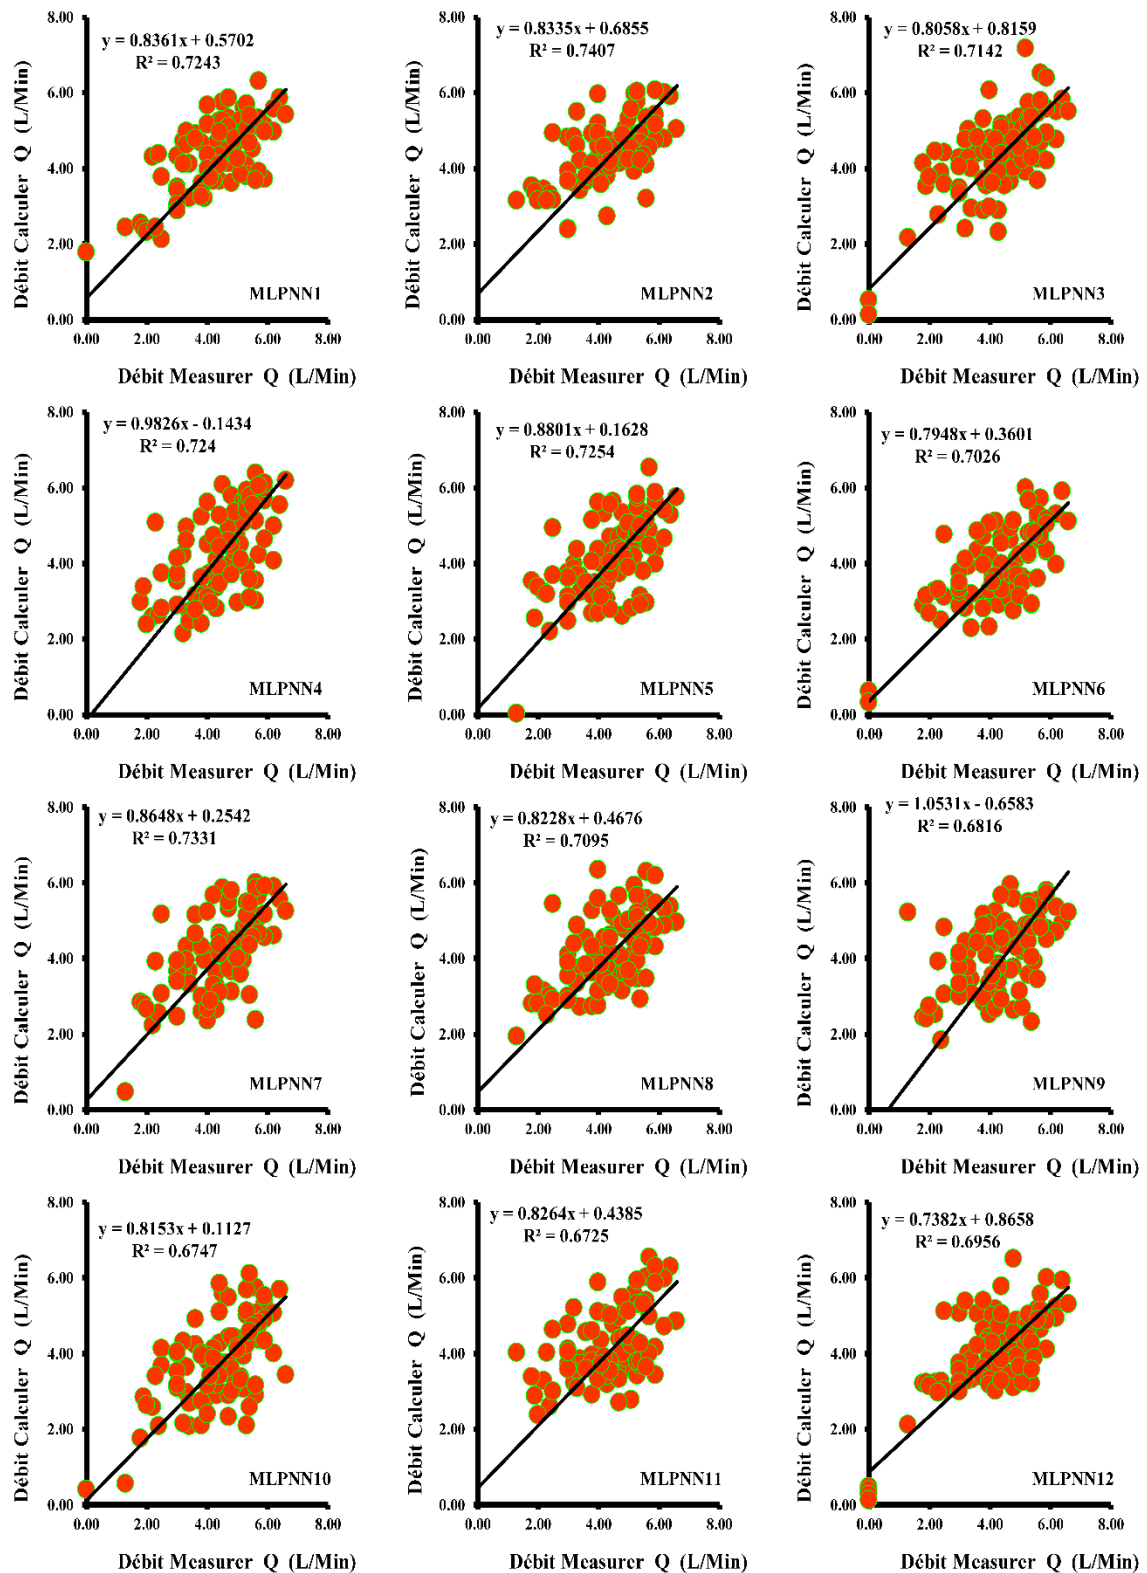


Figure V. 11. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents MLPNN modèles: barrage Zit Emba & phase de validation.

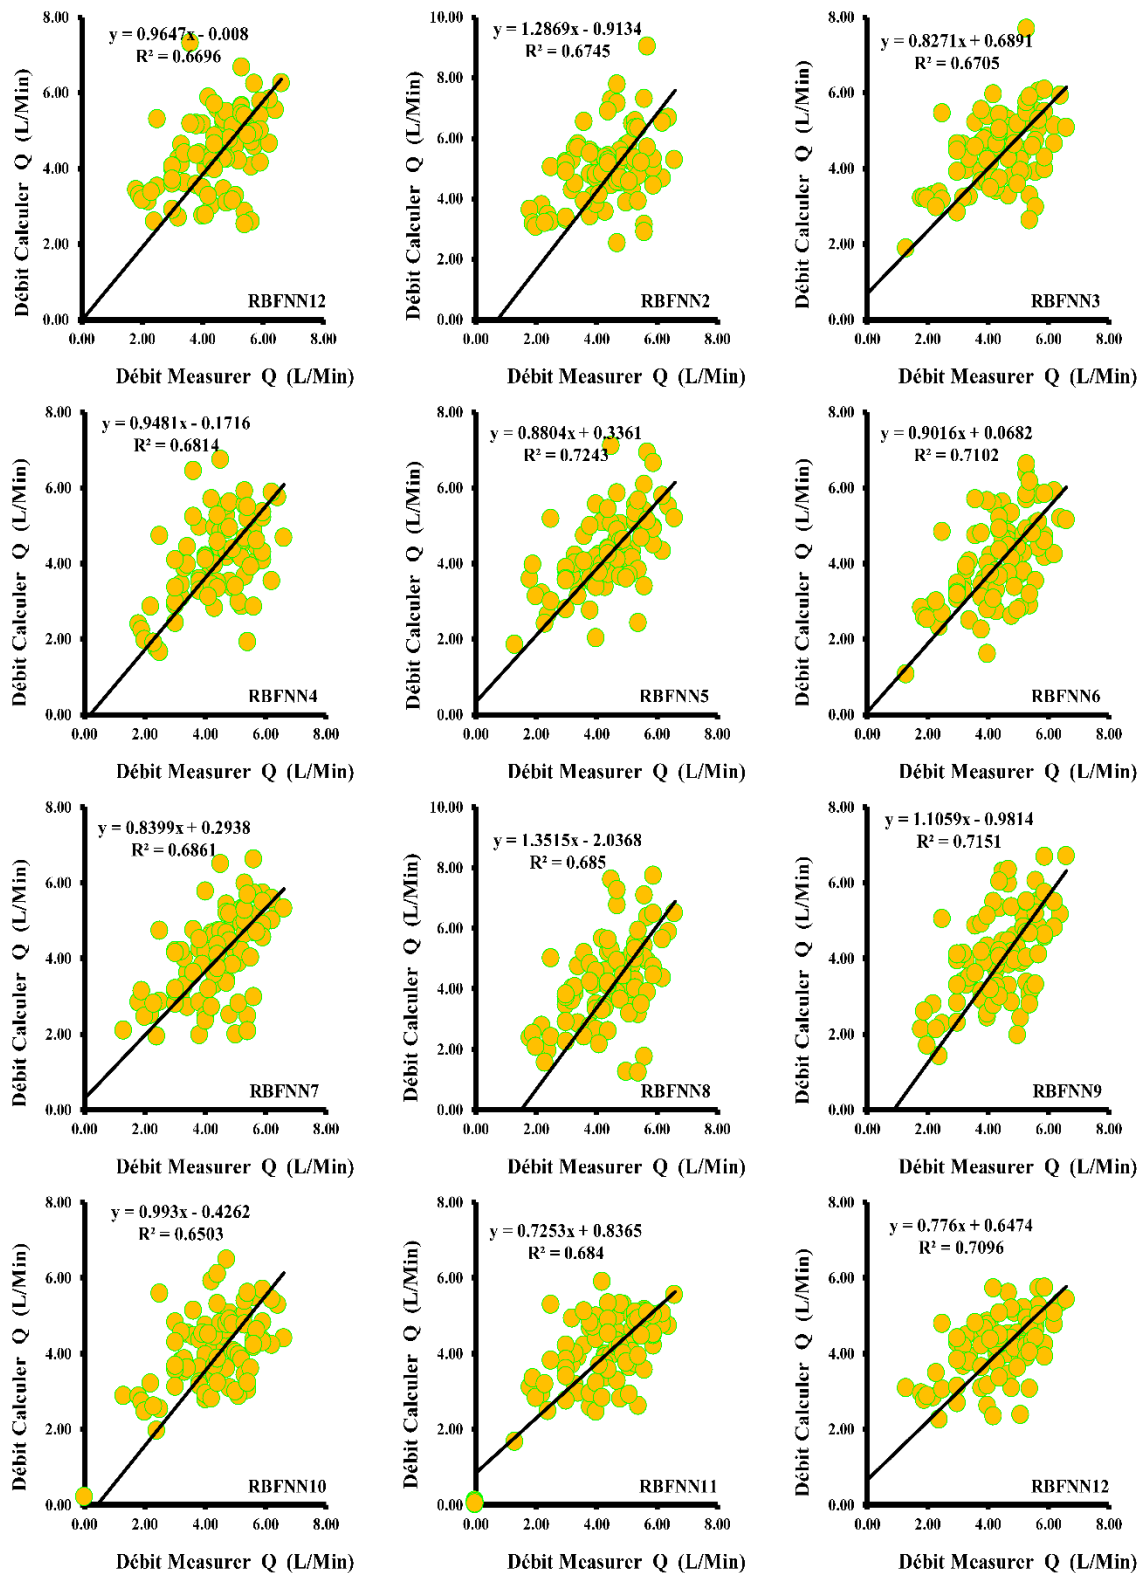


Figure V. 12. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents RBFNN modèles: barrage Zit Emba & phase de validation.

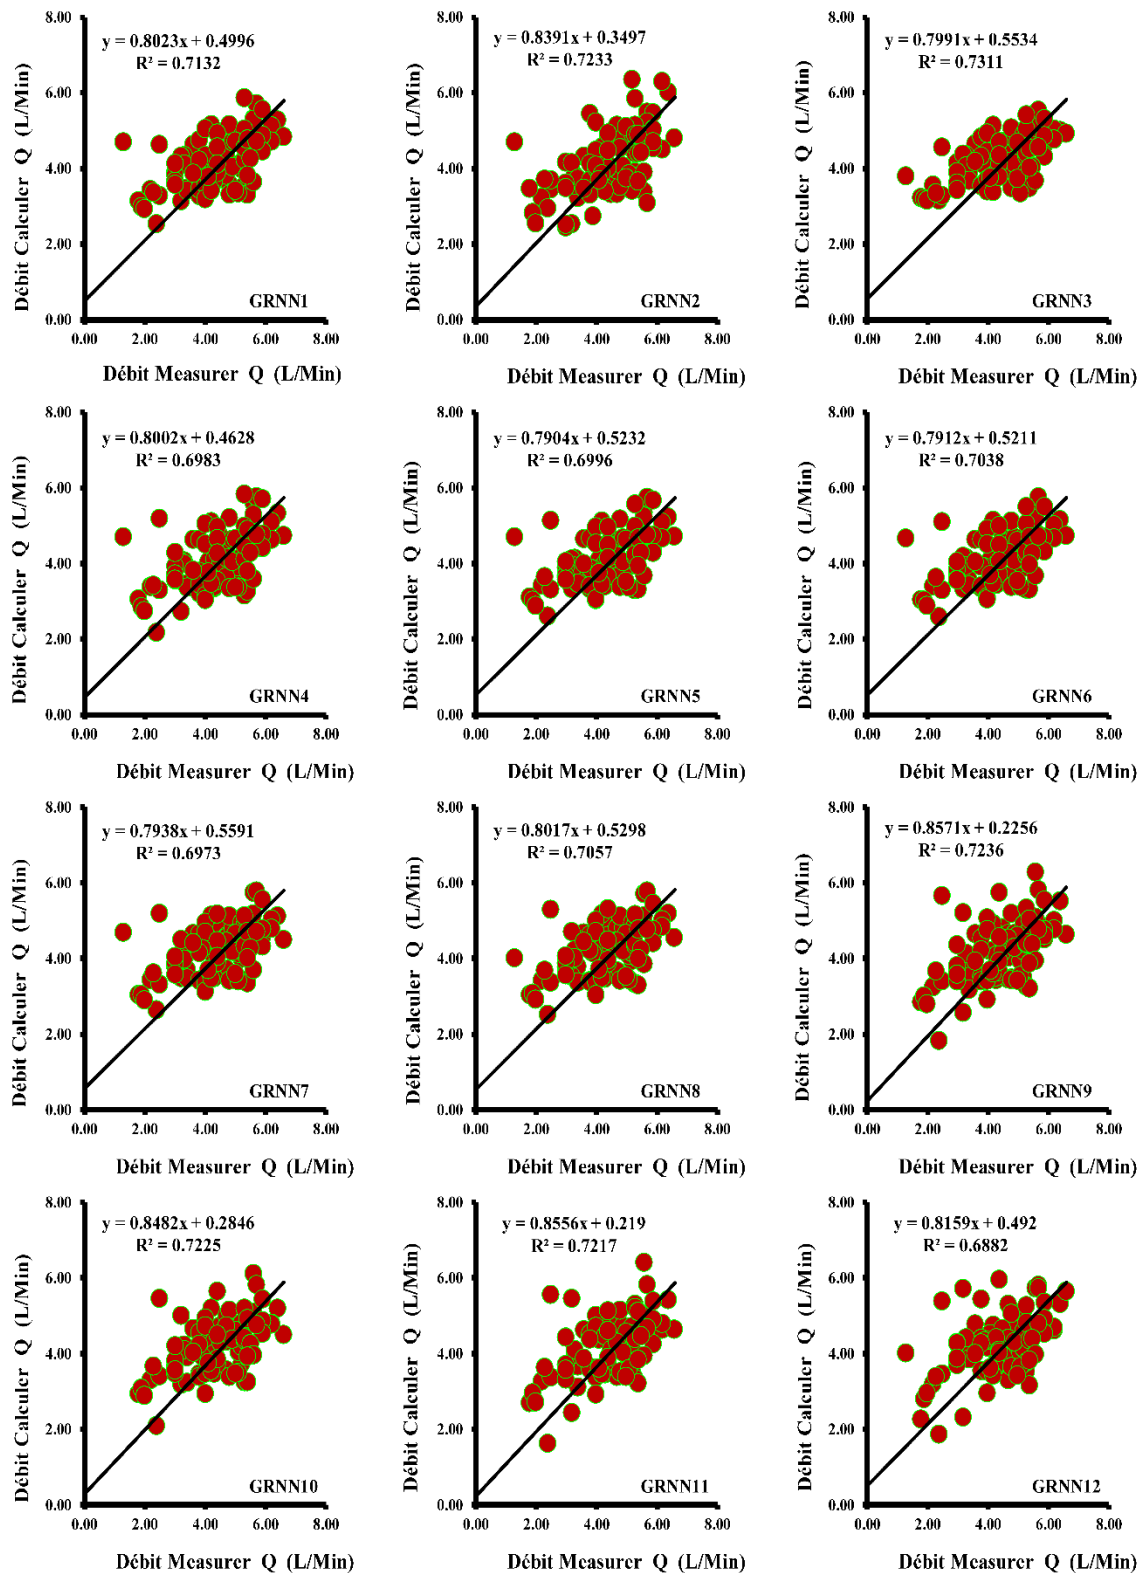


Figure V. 13. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents GRNN modèles: barrage Zit Emba & phase de validation.

**Tableau V. 11.** Performances des différents modèles de RBFNN & barrage Zit Emba.

| Modèles | Training |       |       |       | Validation |        |       |       |
|---------|----------|-------|-------|-------|------------|--------|-------|-------|
|         | R        | NSE   | RMSE  | MAE   | R          | NSE    | RMSE  | MAE   |
| RBFNN1  | 0.923    | 0.852 | 0.596 | 0.444 | 0.818      | 0.532  | 1.183 | 0.942 |
| RBFNN2  | 0.922    | 0.850 | 0.599 | 0.459 | 0.821      | 0.103  | 1.638 | 1.301 |
| RBFNN3  | 0.927    | 0.860 | 0.579 | 0.454 | 0.819      | 0.634  | 1.047 | 0.830 |
| RBFNN4  | 0.934    | 0.872 | 0.553 | 0.421 | 0.825      | 0.530  | 1.186 | 0.933 |
| RBFNN5  | 0.922    | 0.850 | 0.599 | 0.440 | 0.851      | 0.685  | 0.972 | 0.759 |
| RBFNN6  | 0.922    | 0.850 | 0.600 | 0.448 | 0.843      | 0.625  | 1.060 | 0.857 |
| RBFNN7  | 0.900    | 0.810 | 0.674 | 0.490 | 0.828      | 0.614  | 1.075 | 0.818 |
| RBFNN8  | 0.917    | 0.841 | 0.617 | 0.444 | 0.828      | -0.107 | 1.820 | 1.310 |
| RBFNN9  | 0.901    | 0.813 | 0.670 | 0.491 | 0.846      | 0.395  | 1.346 | 1.047 |
| RBFNN10 | 0.894    | 0.799 | 0.693 | 0.521 | 0.806      | 0.401  | 1.339 | 1.056 |
| RBFNN11 | 0.866    | 0.750 | 0.774 | 0.562 | 0.827      | 0.662  | 1.006 | 0.811 |
| RBFNN12 | 0.814    | 0.662 | 0.899 | 0.672 | 0.842      | 0.685  | 0.970 | 0.798 |

**Tableau V. 12.** Performances des différents modèles de GRNN & barrage Zit Emba.

| Modèles | Training |       |       |       | Validation |       |       |       |
|---------|----------|-------|-------|-------|------------|-------|-------|-------|
|         | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE  | MAE   |
| GRNN1   | 0.946    | 0.888 | 0.519 | 0.375 | 0.845      | 0.676 | 0.984 | 0.814 |
| GRNN2   | 0.954    | 0.909 | 0.468 | 0.329 | 0.850      | 0.678 | 0.981 | 0.794 |
| GRNN3   | 0.895    | 0.794 | 0.703 | 0.507 | 0.855      | 0.706 | 0.938 | 0.796 |
| GRNN4   | 0.957    | 0.910 | 0.465 | 0.328 | 0.836      | 0.649 | 1.025 | 0.841 |
| GRNN5   | 0.938    | 0.873 | 0.552 | 0.393 | 0.836      | 0.658 | 1.012 | 0.832 |
| GRNN6   | 0.933    | 0.863 | 0.572 | 0.405 | 0.839      | 0.663 | 1.004 | 0.825 |
| GRNN7   | 0.916    | 0.833 | 0.633 | 0.439 | 0.835      | 0.663 | 1.004 | 0.827 |
| GRNN8   | 0.925    | 0.849 | 0.602 | 0.417 | 0.840      | 0.672 | 0.991 | 0.827 |
| GRNN9   | 0.962    | 0.920 | 0.438 | 0.295 | 0.851      | 0.661 | 1.007 | 0.844 |
| GRNN10  | 0.937    | 0.872 | 0.553 | 0.378 | 0.850      | 0.668 | 0.996 | 0.837 |
| GRNN11  | 0.963    | 0.922 | 0.431 | 0.295 | 0.850      | 0.656 | 1.014 | 0.853 |
| GRNN12  | 0.965    | 0.926 | 0.421 | 0.284 | 0.830      | 0.647 | 1.028 | 0.865 |

À partir des résultats obtenus et la comparaison entre les différents modèles au niveau du barrage de Zit Emba, nous pouvons tirer les conclusions suivantes:

- 1) Les meilleures performances ont été obtenues avec des inputs différentes. Les meilleures performances avec le MLPNN ont été obtenues avec dans la combinaison N°2 après l'élimination des variables d'entrée du calendrier grégorien. Pour le RBFNN, la combinaison N°5 était la meilleure, alors que pour le GRNN, la combinaison N°7 était la meilleure.
- 2) Après l'élimination des variables d'entrée du calendrier grégorien dans la combinaison N°2, on observe une amélioration des performances dans les trois approches.
- 3) Après l'élimination des variables d'entrée relatives au niveau d'eau dans le réservoir, dans la combinaison N°3, on observe une détérioration des performances pour l'approche MLPNN, tandis que pour les approches RBFNN et GRNN, on observe une amélioration des performances.

- 4) Dans la combinaison N°12, en utilisant uniquement les variables d'entrée du calendrier grégorien et du niveau d'eau dans le réservoir, les trois approches donnent des performances acceptables avec un R supérieure à 0.830.
- 5) Bien que tous les modèles aient montré des performances relativement similaires, MLPNN a illustré les meilleures performances.
- 6) Les meilleurs modèles sont comparés en utilisant les figures Boxplot et Violinplot (Figure V.14) et par le diagram de Taylor (Figure V.15).




Figure V. 14. Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Zit Emba.




Figure V. 15. Le diagramme de Taylor pour la comparaison entre les meilleurs modèles ANN: Barrage Zit Emba.

### V.7. Résultats Obtenus par les modèles ANN: Barrage Foum el Khanga

Le **Tableau V.13** présente les structures des douze modèles de réseaux de neurone artificielle utilisés pour le barrage de Foum el Khanga sur Oued Cheraf. Les résultats obtenus par les différents modèles sont récapitulés dans les **Tableaux 14-16**. La remarque importante à signaler est que, les performances des modèles sont meilleures en phase d'apprentissage qu'en phase de validation et cela pour les trois approches, i.e., les MLPNN, RBFNN et GRNN.

**Tableau V. 13.** Structure des modèles utilisées dans Barrage Foum el Khanga.

| N° | Modèles | Variables d'entrées (les inputs)                             | Output  |
|----|---------|--|---------|
| 01 | M1      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, PZ7, PZ8, PZ9, CPE | Q (L/S) |
| 02 | M2      | P1, PZ2, PZ3, PZ4, PZ5, PZ6, PZ7, PZ8, PZ9, CPE              | Q (L/S) |
| 03 | M3      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, PZ7, PZ8, PZ9      | Q (L/S) |
| 04 | M4      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, PZ7, PZ8, CPE      | Q (L/S) |
| 05 | M5      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, PZ7, CPE           | Q (L/S) |
| 06 | M6      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, PZ6, CPE                | Q (L/S) |
| 07 | M7      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, PZ5, CPE                     | Q (L/S) |
| 08 | M8      | YY, MM, DD, PZ1, PZ2, PZ3, PZ4, CPE                          | Q (L/S) |
| 09 | M9      | YY, MM, DD, PZ1, PZ2, PZ3, CPE                               | Q (L/S) |
| 10 | M10     | YY, MM, DD, PZ1, PZ2, CPE                                    | Q (L/S) |
| 11 | M11     | YY, MM, DD, PZ1, CPE   | Q (L/S) |
| 12 | M12     | YY, MM, DD, CPE  | Q (L/S) |

**Tableau V. 14.** Performances des différents modèles de MLPNN & barrage Foum el Khanga.

| Models  | Training |       |       |       | Validation |        |       |       |
|---------|----------|-------|-------|-------|------------|--------|-------|-------|
|         | R        | NSE   | RMSE  | MAE   | R          | NSE    | RMSE  | MAE   |
| MLPNN1  | 0.926    | 0.850 | 0.066 | 0.039 | 0.713      | 0.471  | 0.136 | 0.091 |
| MLPNN2  | 0.836    | 0.699 | 0.093 | 0.062 | 0.763      | 0.520  | 0.130 | 0.104 |
| MLPNN3  | 0.831    | 0.679 | 0.096 | 0.072 | 0.592      | 0.285  | 0.159 | 0.129 |
| MLPNN4  | 0.829    | 0.684 | 0.096 | 0.064 | 0.681      | 0.385  | 0.147 | 0.106 |
| MLPNN5  | 0.797    | 0.633 | 0.103 | 0.074 | 0.653      | 0.339  | 0.152 | 0.106 |
| MLPNN6  | 0.690    | 0.474 | 0.123 | 0.095 | 0.642      | 0.393  | 0.146 | 0.116 |
| MLPNN7  | 0.915    | 0.833 | 0.069 | 0.045 | 0.652      | 0.252  | 0.162 | 0.119 |
| MLPNN8  | 0.804    | 0.609 | 0.106 | 0.079 | 0.701      | 0.395  | 0.146 | 0.111 |
| MLPNN9  | 0.803    | 0.638 | 0.102 | 0.072 | 0.688      | 0.460  | 0.138 | 0.103 |
| MLPNN10 | 0.781    | 0.585 | 0.110 | 0.081 | 0.684      | 0.464  | 0.137 | 0.106 |
| MLPNN11 | 0.826    | 0.682 | 0.096 | 0.062 | 0.668      | 0.344  | 0.152 | 0.109 |
| MLPNN12 | 0.947    | 0.877 | 0.060 | 0.042 | 0.596      | -0.292 | 0.213 | 0.170 |

En analysant les résultats obtenus par les modèles MLPNN en phase d'apprentissage, on remarque que le modèle MLPNN12 était le meilleur avec les performances les plus élevées. Le MLPNN12 assure un R= 0.947 et un NSE=0.877, indiquant une forte corrélation entre les débits calculés et mesurés. De plus, il présente les plus faibles valeurs d'erreur quadratique moyenne (RMSE= 0.060) et d'erreur moyenne absolue (MAE=0.042), indiquant de faibles écarts entre les débits calculés et mesurés. En revanche, le MLPNN6 présente les performances les plus faibles dans la phase d'apprentissage. Il assure un R=0.690 et un critère NSE= 0.474, indiquant une relation très faible entre les débits calculés et mesurés. De plus, il présente des valeurs des (RMSE= 0.123) et (MAE = 0.095) les plus élevées. En phase de validation, le MLPNN1 se présente comme le modèle supérieur parmi les douze modèles. Il assure un R=0.713 et un NSE=0.471, plus faible que les valeurs obtenues en phase d'apprentissage. Cependant, les valeurs des RMSE=0.136 et MAE=0.091 sont relativement plus grandes par rapport à la phase

d'apprentissage, indiquant des écarts plus importants entre les débits calculer et mesurés. En revanche, le MLPNN12 assure les performances les plus faible dans la phase de validation, avec un  $R=0.596$  et un  $NSE=-0.292$ . La valeur de  $NSE$  négative suggère que le modèle se comporte moins bien qu'une simple moyenne des valeurs mesurés. De plus, il présente les valeurs les plus élevées des  $RMSE=0.213$  et  $MAE=0.170$ , indiquant des écarts significatifs entre les débits calculés et mesurés. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents MLPNN (barrage Fom El Khanga) sont reportés dans la **Figure V.16**.

Le **Tableau V.15** présente les performances numériques des différents RBFNN modèles en phases d'apprentissage et de validation. En phase d'apprentissage, les modèles RBFNN présentent généralement de bonnes performances, avec des coefficients  $R$  et  $NSE$  relativement élevés. Parmi les modèles, le RBFNN2 présente les meilleures performances. Il assure un  $R=0.906$  et un  $NSE=0.820$ , indiquant une forte relation linéaire et une concordance entre les débits calculés et mesurés. De plus, le RBFNN2 présente les valeurs les plus faibles des  $RMSE=0.072$ ) et  $MAE=0.042$ , suggérant de faibles écarts entre les valeurs des débits calculés et mesurés. En revanche, le RBFNN7 présente des performances relativement plus faibles dans la phase d'apprentissage, avec un  $R=0.860$  et un  $NSE$  plus faible ( $NSE = 0.739$ ), indiquant une relation et une concordance plus faibles entre les débits calculés et mesurés. De plus, il présente des valeurs plus élevées des  $RMSE=0.087$  et  $MAE=0.063$ ), suggérant des écarts plus importants entre les valeurs prédites et réelles. Dans la phase de validation, le modèle RBFNN4 émerge comme le modèle supérieur parmi les douze modèles. Il assure un  $R = 0.725$ ) et un  $NSE=0.264$ , bien que plus faible que dans la phase d'apprentissage. Cependant, les valeurs des  $RMSE=0.076$  et  $MAE=0.053$ ) sont relativement plus faible, indiquant des faibles écarts entre les débits calculés et mesurés, par rapport à la phase d'apprentissage. En revanche, le RBFNN11 se présente comme le plus faible en phase de validation, avec un  $R= 0.574$  et un  $NSE=-0.089$ . La valeur  $NSE$  négative suggère que le modèle se comporte moins bien qu'une simple moyenne des valeurs observées. De plus, le RBFNN10 présente les valeurs les plus élevées des  $RMSE=0.262$  et  $MAE=0.202$ , indiquant des écarts significatifs entre les débits calculés et mesurés. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents RBFNN (barrage Fom El Khanga) sont reportés dans la **Figure V.17**.

Les résultats obtenus par le modèle GRNN sont reportés dans le **Tableau V.16**. En phase d'apprentissage, le modèle GRNN2 émerge comme le modèle supérieur, atteignant un  $R$  élevé ( $R=0.970$ ) et un  $NSE=0.939$ . Ces valeurs indiquent une forte relation linéaire et un bon accord entre les débits prédits et réels. De plus, GRNN2 présente les valeurs les plus faibles de  $RMSE$  (0.042) et de  $MAE$  (0.016), suggérant des écarts minimales entre les valeurs calculés et mesurés. En revanche, le GRNN5 assure des performances relativement moins bonnes lors de la phase d'apprentissage, avec un coefficient de corrélation plus faible ( $R=0.723$ ) et un ( $NSE=0.472$ ). De plus, il assure des valeurs de  $RMSE=0.124$  et  $MAE=0.092$ , plus élevées. Dans la phase de validation, le GRNN2 se présente toujours comme le meilleur modèle parmi les douze modèles. Il atteint un  $R= 0.712$  et un  $NSE=0.416$ , bien que plus basse que dans la phase d'apprentissage. Cependant, les valeurs de  $RMSE=0.143$  et de  $MAE=0,080$  sont relativement élevées, suggérant des écarts plus importants entre les débits prédits et observés par rapport à la phase

d'apprentissage. En revanche, le GRNN3 présente les performances les plus faibles dans la phase de validation, avec un coefficient R relativement faible ( $R=0.529$ ) et un  $NSE=0.264$ . Il présente également des valeurs de  $RMSE=0.161$  et de  $MAE=0.125$  plus élevées. En général, la plupart des modèles GRNN présentent une similarité remarquable et ont affiché des performances relativement faibles. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents GRNN (barrage Foum El Khanga) sont reportés dans la **Figure V.18**.

**Tableau V. 15.** Performances des différents modèles de RBFNN & barrage Foum el Khanga.

| Models  | Training |       |       |       | Validation |        |       |       |
|---------|----------|-------|-------|-------|------------|--------|-------|-------|
|         | R        | NSE   | RMSE  | MAE   | R          | NSE    | RMSE  | MAE   |
| RBFNN1  | 0.902    | 0.813 | 0.074 | 0.052 | 0.709      | 0.230  | 0.165 | 0.125 |
| RBFNN2  | 0.906    | 0.820 | 0.072 | 0.042 | 0.698      | 0.134  | 0.175 | 0.135 |
| RBFNN3  | 0.882    | 0.778 | 0.080 | 0.054 | 0.609      | 0.123  | 0.176 | 0.125 |
| RBFNN4  | 0.895    | 0.800 | 0.076 | 0.053 | 0.725      | 0.264  | 0.161 | 0.123 |
| RBFNN5  | 0.867    | 0.751 | 0.085 | 0.063 | 0.720      | 0.325  | 0.154 | 0.117 |
| RBFNN6  | 0.890    | 0.792 | 0.078 | 0.055 | 0.690      | 0.065  | 0.181 | 0.141 |
| RBFNN7  | 0.860    | 0.739 | 0.087 | 0.063 | 0.720      | 0.316  | 0.155 | 0.117 |
| RBFNN8  | 0.886    | 0.785 | 0.079 | 0.055 | 0.701      | 0.251  | 0.162 | 0.124 |
| RBFNN9  | 0.873    | 0.763 | 0.083 | 0.057 | 0.657      | 0.173  | 0.171 | 0.129 |
| RBFNN10 | 0.894    | 0.800 | 0.076 | 0.052 | 0.633      | -0.948 | 0.262 | 0.202 |
| RBFNN11 | 0.884    | 0.781 | 0.080 | 0.056 | 0.574      | -0.089 | 0.196 | 0.143 |
| RBFNN12 | 0.895    | 0.802 | 0.076 | 0.053 | 0.694      | 0.328  | 0.154 | 0.110 |

**Tableau V. 16.** Performances des différents modèles de GRNN & barrage Foum el Khanga.

| Models | Training |       |       |       | Validation |       |       |       |
|--------|----------|-------|-------|-------|------------|-------|-------|-------|
|        | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE  | MAE   |
| GRNN1  | 0.755    | 0.526 | 0.117 | 0.084 | 0.569      | 0.317 | 0.155 | 0.123 |
| GRNN2  | 0.970    | 0.939 | 0.042 | 0.016 | 0.712      | 0.416 | 0.143 | 0.080 |
| GRNN3  | 0.780    | 0.574 | 0.111 | 0.077 | 0.529      | 0.264 | 0.161 | 0.125 |
| GRNN4  | 0.734    | 0.492 | 0.121 | 0.088 | 0.568      | 0.317 | 0.155 | 0.125 |
| GRNN5  | 0.723    | 0.472 | 0.124 | 0.092 | 0.557      | 0.304 | 0.156 | 0.127 |
| GRNN6  | 0.786    | 0.584 | 0.110 | 0.077 | 0.551      | 0.286 | 0.158 | 0.121 |
| GRNN7  | 0.812    | 0.629 | 0.104 | 0.070 | 0.577      | 0.311 | 0.156 | 0.115 |
| GRNN8  | 0.775    | 0.561 | 0.113 | 0.081 | 0.575      | 0.322 | 0.154 | 0.120 |
| GRNN9  | 0.754    | 0.525 | 0.117 | 0.087 | 0.575      | 0.327 | 0.154 | 0.123 |
| GRNN10 | 0.795    | 0.588 | 0.109 | 0.078 | 0.592      | 0.345 | 0.152 | 0.120 |
| GRNN11 | 0.797    | 0.596 | 0.108 | 0.077 | 0.596      | 0.349 | 0.151 | 0.118 |
| GRNN12 | 0.885    | 0.759 | 0.084 | 0.052 | 0.556      | 0.249 | 0.163 | 0.115 |

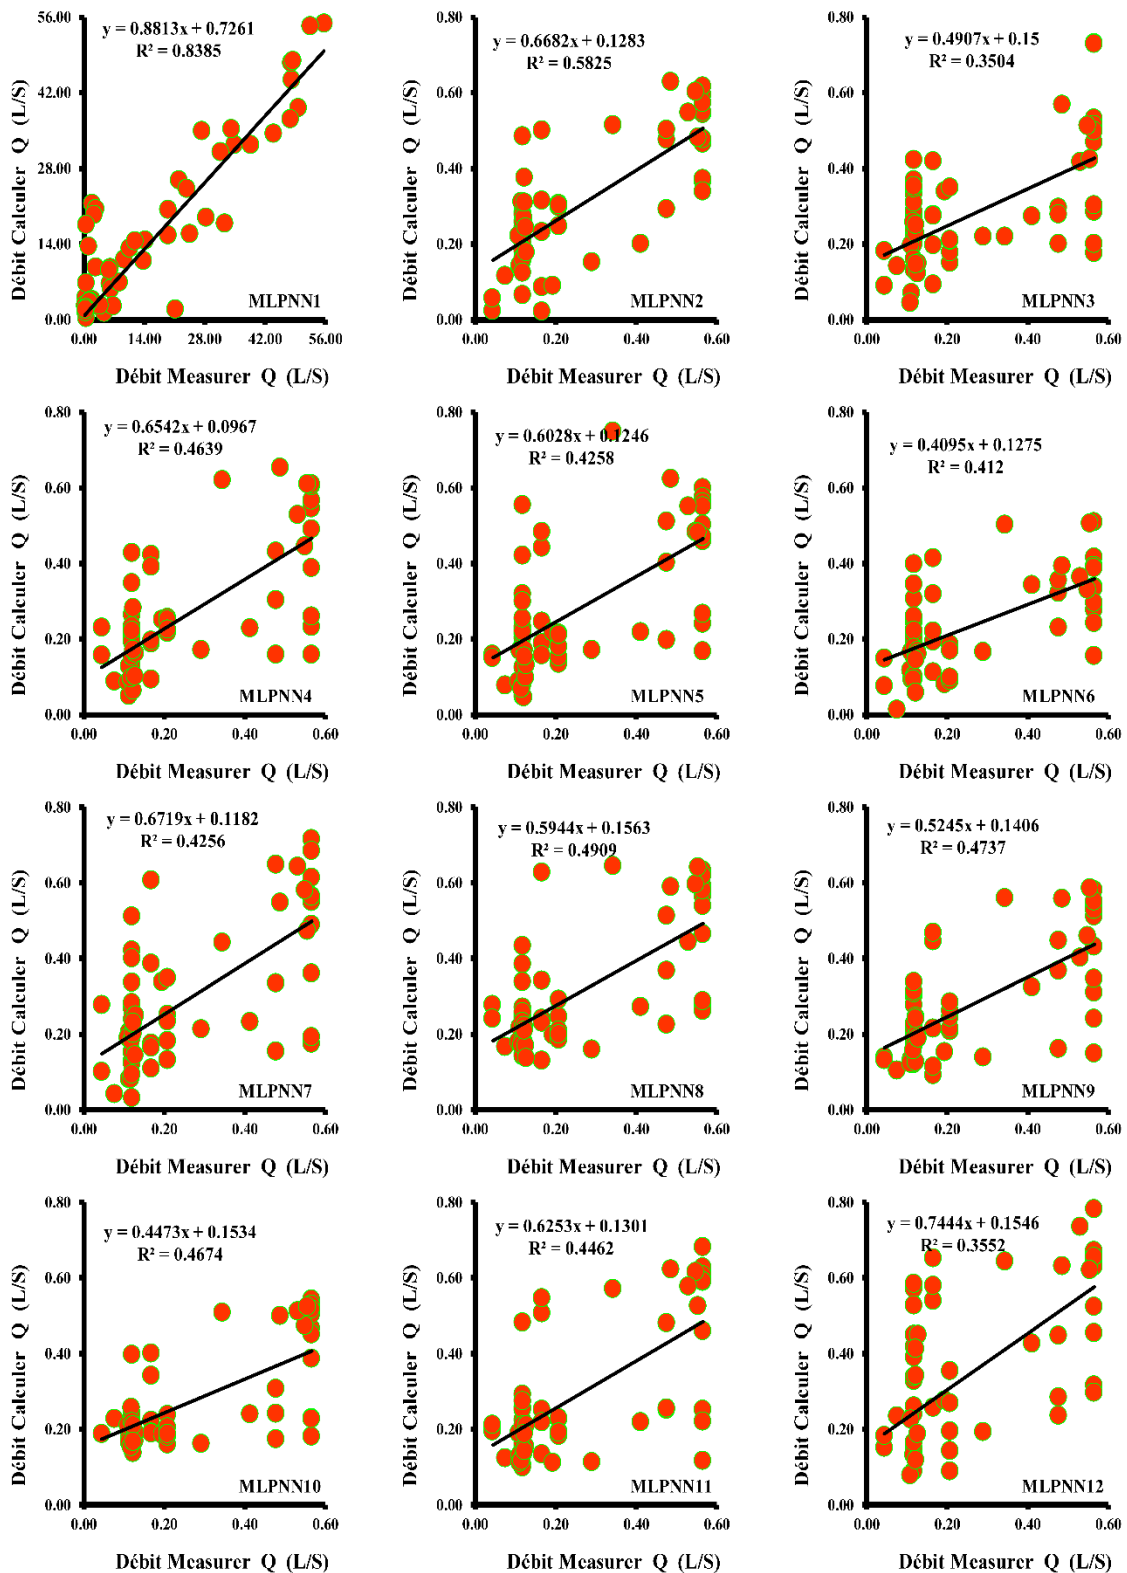
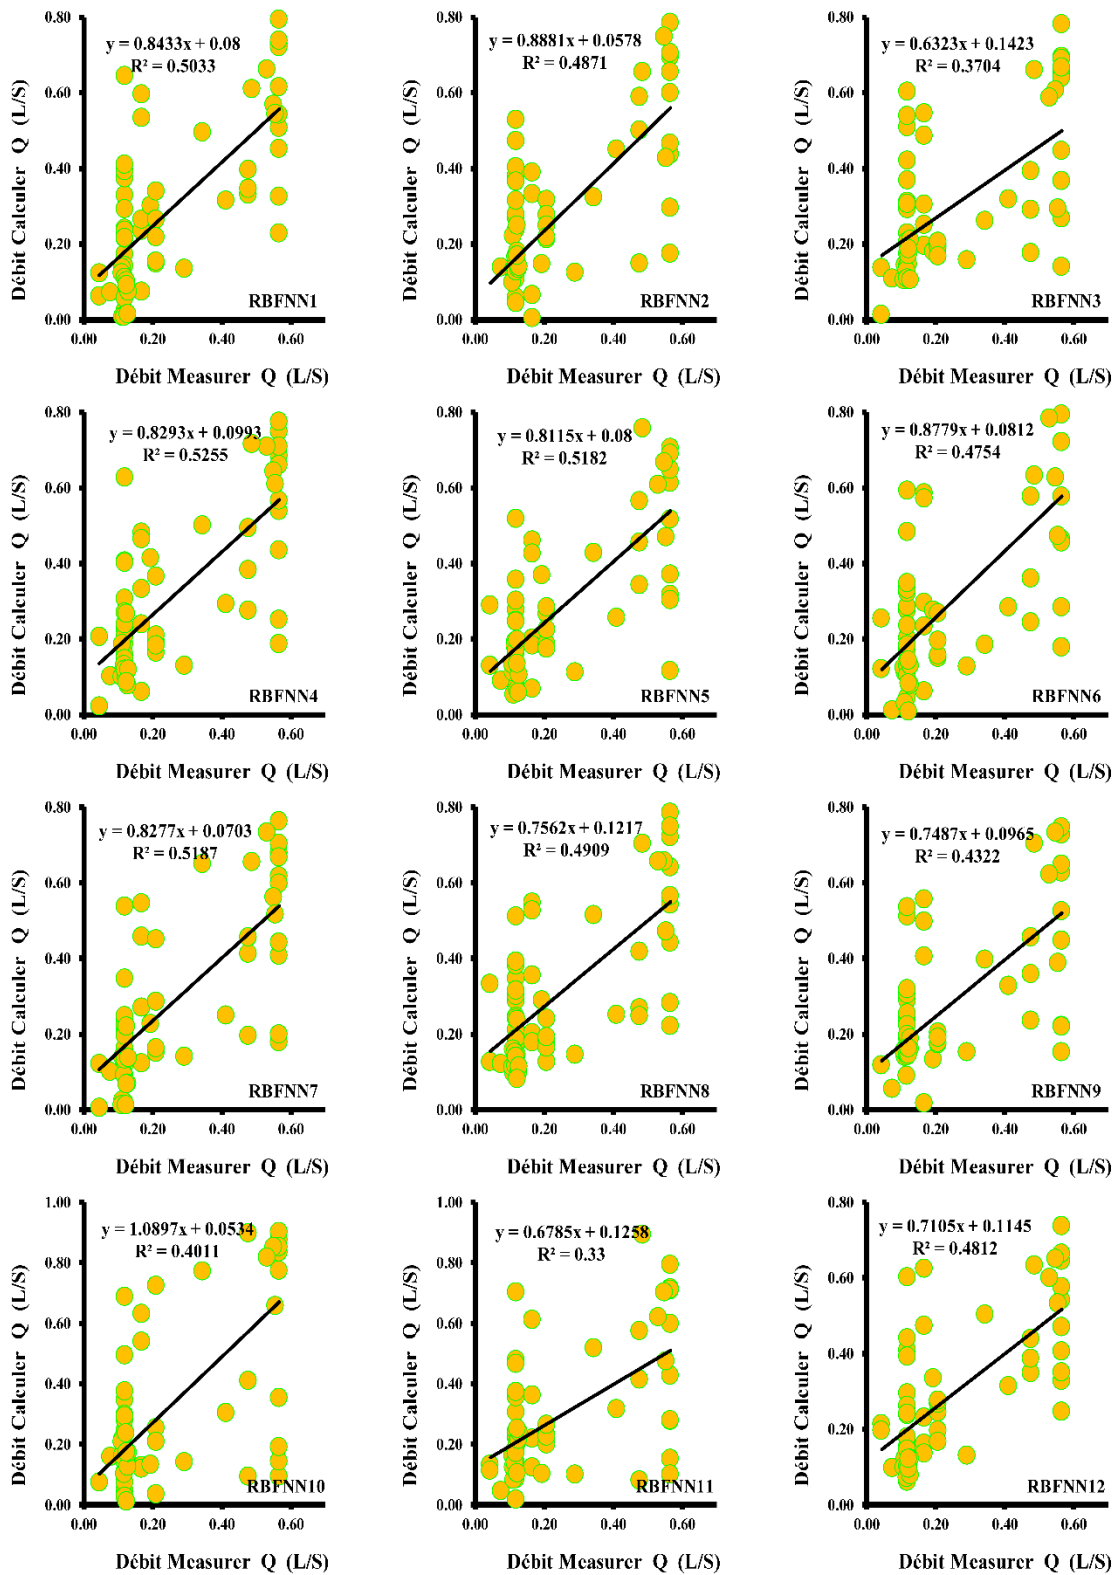


Figure V. 16. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents MLPNN modèles: barrage Foug El Khanga & phase de validation.



**Figure V. 17.** Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents RBFNN modèles: barrage Fom El Khanga & phase de validation.

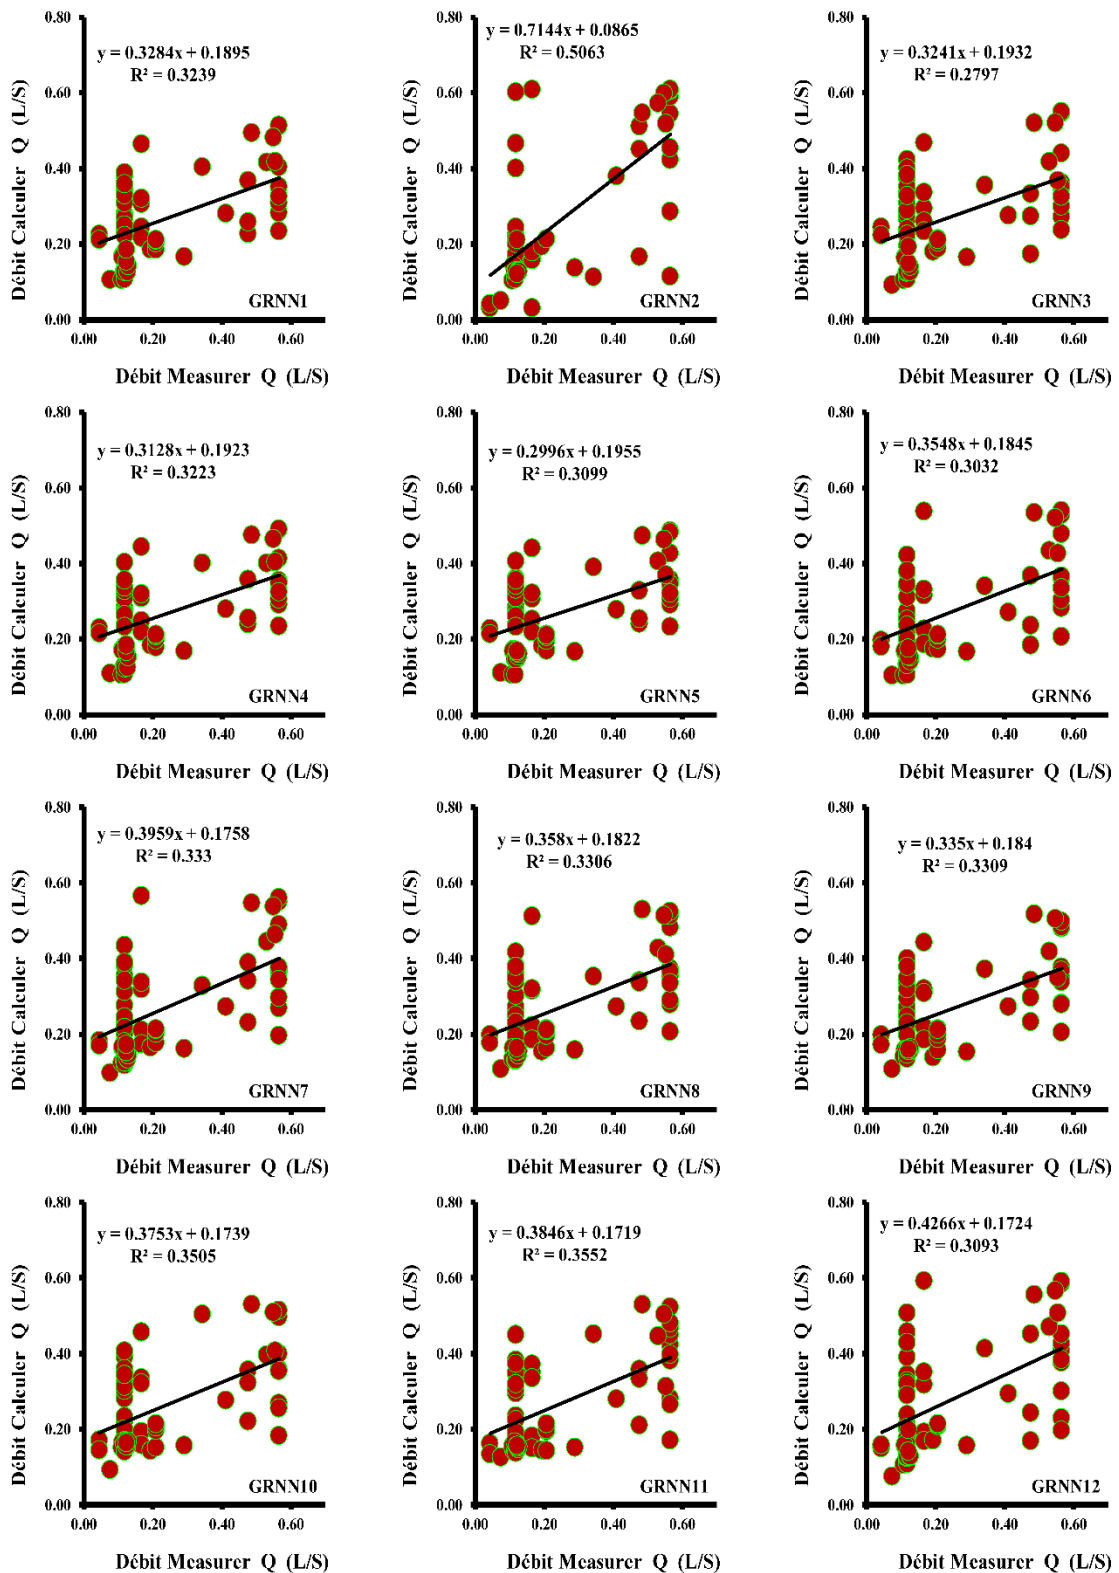
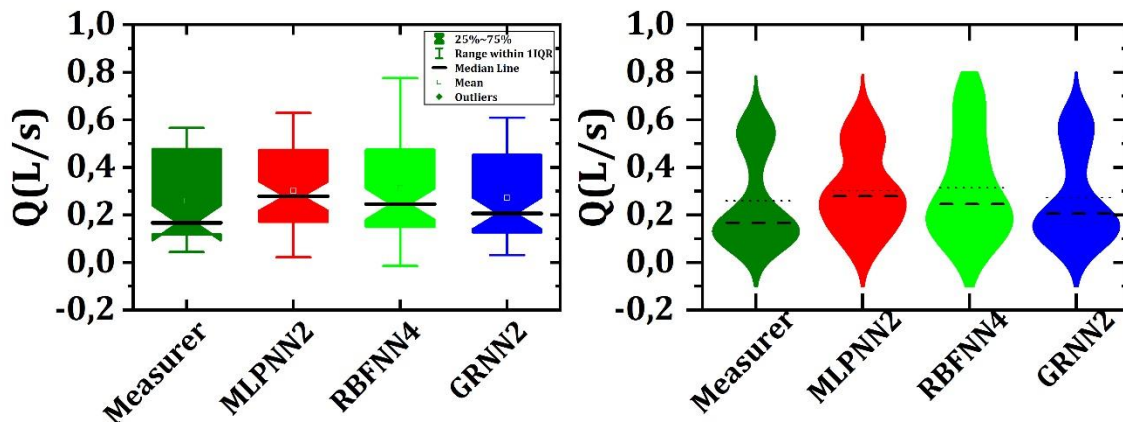



Figure V. 18. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents GRNN modèles: barrage Fom El Khanga & phase de validation.

Les résultats obtenus au niveau du barrage Foug El Khanga nous permet de conclure ce qui suit :

1. La combinaison N°2 a permis d'obtenir les meilleures performances pour les modèles MLPNN et GRNN sans tenir compte des variables du calendrier grégorien, cependant nous avons remarqué une dégradation des performances pour le modèle RBFNN.
2. En revanche, après l'élimination de la variable cote du plan d'eau dans le réservoir (CPE), on observe une dégradation des performances pour les trois approches.
3. En comparant les performances des combinaisons N°3 et N°12, on remarque qu'en utilisant uniquement la variable d'entrée du niveau d'eau dans le réservoir (CPE), on obtient de meilleures performances.
4. Finalement, une comparaison entre les meilleurs modèles est présentée en termes graphique sur les deux **Figures V.19** et **V.20**.



**Figure V. 19.** Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Foug el Khanga.



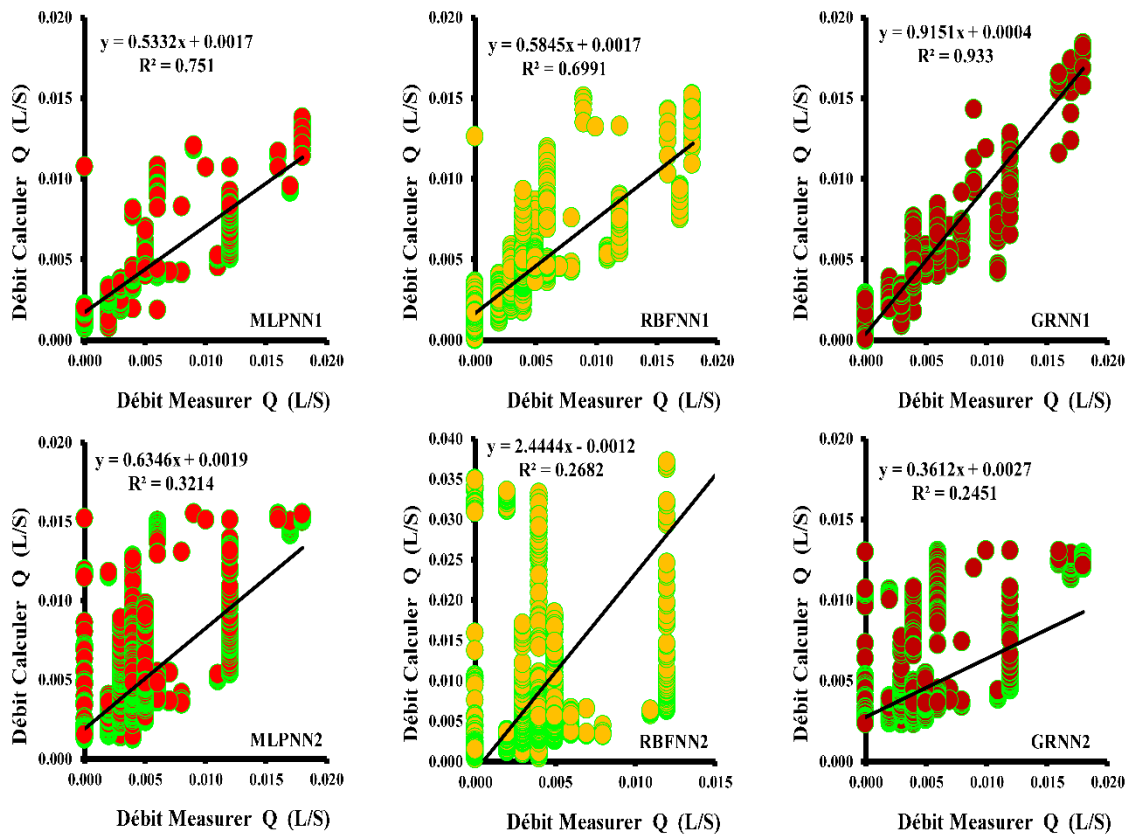
**Figure V. 20.** Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles: Barrage Foug el Khanga.

### V.8. Résultats Obtenus par les modèles ANN: Barrage Hammam Debagh

Pour le barrage Hammam Debagh, on ne dispose pas des relevés piézométriques, et nous avons tenté de modéliser les débits de fuites en utilisant uniquement : (i) la cote du plan d'eau (CPE), (ii) le volume du réservoir (VOL), et (iii) les composantes du calendrier grégorien. Nous avons comparé uniquement entre deux modèles: (i) le modèle M1 qui utilise les CPE, VOL et les composantes du calendrier grégorien, et (ii) le modèle M2 qui utilise uniquement les CPE et VOL. Les résultats obtenus par les différents modèles sont reportés dans le **Tableau V.17** et la **Figure V.21**, en termes de Scatterplot.

**Tableau V. 17.** Performances des différents modèles ANN & barrage Hammam Debagh.

| Models | Training |       |       |       | Validation |         |       |       |
|--------|----------|-------|-------|-------|------------|---------|-------|-------|
|        | R        | NSE   | RMSE  | MAE   | R          | NSE     | RMSE  | MAE   |
| MLPNN1 | 0.915    | 0.836 | 0.001 | 0.001 | 0.867      | 0.688   | 0.002 | 0.001 |
| MLPNN2 | 0.693    | 0.468 | 0.002 | 0.005 | 0.567      | -0.014  | 0.003 | 0.002 |
| RBFNN1 | 0.849    | 0.721 | 0.002 | 0.001 | 0.836      | 0.679   | 0.002 | 0.001 |
| RBFNN2 | 0.844    | 0.713 | 0.002 | 0.001 | 0.518      | -19.312 | 0.014 | 0.006 |
| GRNN1  | 0.996    | 0.992 | 0.000 | 0.000 | 0.966      | 0.932   | 0.001 | 0.000 |
| GRNN2  | 0.660    | 0.353 | 0.002 | 0.002 | 0.495      | 0.177   | 0.003 | 0.002 |



**Figure V. 21.** Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles ANN: barrage Hammam Debagh & phase de validation.

En phase d'apprentissage, le modèle MLPNN1 a présenté une forte corrélation ( $R=0.915$ ) et un NSE de 0.836 ce qui représente une bonne performance. Les valeurs de RMSE et MAE de 0.001 indiquent de faibles écarts de prédiction entre les valeurs mesurés et calculés. En revanche, le MLPNN2 a affiché une corrélation plus faible ( $R=0.693$ ) et un NSE de 0.468, indiquant de faible performance. Les valeurs de RMSE et MAE de 0.002 et 0.005 montrent des écarts légèrement plus importants par rapport à MLPNN1. Pendant la phase de validation, MLPNN1 a maintenu sa performance supérieure avec un R de 0.867 et un NSE de 0.688, et des valeurs de RMSE et MAE de 0.002 et 0.001, alors que les performances du modèle MLPNN2 était inférieure avec un R de 0.567 et un NSE de -0,014. Ces résultats confirment l'importance des composantes du calendrier Grégorien. Pour les modèles RBFNN, le RBFNN1 a montré une corrélation modérée ( $R=0.849$ ) et un NSE de 0.721, indiquant une performance acceptable pour la prédiction de débit des fuites. De manière similaire, le modèle RBFNN2 a présenté une corrélation similaire ( $R=0.844$ ) et un NSE de 0.713, suggérant une performance acceptable aussi. Pendant la phase de validation, le modèle RBFNN1 a maintenu ses performances avec un R de 0.836 et un NSE de 0.679, confirment une faible différence entre les valeurs calculés et mesurés. Les performances du modèle RBFNN2 ont été inférieure avec un R de 0.518 et un NSE de -19.312. Les résultats obtenus avec les modèles RBFNN confirment l'importance des composantes du calendrier Grégorien. Pour les modèles GRNN, en phase d'apprentissage, le GRNN1 a présenté une corrélation exceptionnellement élevée ( $R=0.996$ ) et un NSE de 0.992 représentant une excellente performance de prédiction. En revanche, GRNN2 a montré une corrélation plus faible ( $R=0.660$ ) et un NSE de 0.353, indiquant une performance inférieure. Pendant la phase de validation, le GRNN1 a maintenu sa performance supérieure avec un R de 0.966 et un NSE de 0.932 confirment une faible différence entre les valeurs prédites et réelles. Le GRNN2 a continué de présenter de performance inférieure avec un R de 0.495 et un NSE de 0.177. En résumé, GRNN1 a constamment surpassé GRNN2 tant dans les phases d'apprentissage que de validation. GRNN1 présentait des corrélations plus élevées, des NSE plus élevés et une précision globale supérieure pour reproduire les motifs de débit.

Les résultats obtenus par les différents modèles pour le barrage Hammam Debagh permettent de tirer les conclusions suivantes:

1. Les modèles de la combinaison N°1 présentent les meilleures performances par rapport aux autres modèles.
2. Le modèle GRNN1 a donné des résultats légèrement supérieurs aux autres, avec le meilleur coefficient de corrélation ( $R=0.966$ ), il est suivi par les modèles MLPNN1, RBFNN1, respectivement.
3. Concernant les modèles de la combinaison N°2 (CPE, VOL) ont tous donné des performances médiocres.
4. Les résultats mettent en évidence l'effet positif des variables du calendrier grégorien sur l'amélioration des performances des modèles en termes de précision de prédiction du débit de fuite.




Figure V. 22. Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Hammam Debagh.




Figure V. 23. Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles: Barrage Hammam Debagh.

## V.9. Conclusion

L'originalité de notre travail de modélisation réside dans l'utilisation de différentes techniques de réseaux de neurones artificiels pour prédire les débits de fuite à travers des barrages réservoirs situés dans le nord de l'Algérie. L'intérêt de ces modèles réside dans leur capacité à apprendre des relations complexes à partir de données numériques. Nous avons étudié et discuté de la capacité des techniques MLPNN, RBFNN et GRNN à estimer l'infiltration à travers les barrages en utilisant le niveau piézométrique et le niveau d'eau dans le réservoir. L'étude a démontré la possibilité d'estimer l'infiltration quotidienne en utilisant ces modèles pour différents barrages situés à des endroits différents.

1. Tous les modèles de réseaux de neurone artificiels ont présenté des performances relativement bonnes dans tous les barrages, à l'exception du barrage Foum el Khanga, avec lequel nous avons obtenus de faible performances médiocres pour les trois modèles MLPNN, RBFNN et GRNN.
2. L'approche MLPNN s'est avérée supérieure en termes de performances pour prédire le débit d'infiltration dans quatre barrages sur cinq, ce qui lui confère un avantage par rapport aux autres approches de réseaux de neurone artificiels. En ce qui concerne le barrage de Bouhamdane, l'approche GRNN s'est révélée nettement supérieure dans la prédiction des débits de fuite.

3. L'approche GRNN a montré une supériorité par rapport à l'approche RBFNN dans trois barrages sur cinq.
4. L'inclusion des données de niveau d'eau dans le réservoir comme variable d'entrée a eu un impact positif sur les performances de prédiction du débit de fuite dans la majorité des cas, ce qui fait du niveau d'eau dans le réservoir une variable d'entrée critique.
5. En ce qui concerne l'effet des entrées du calendrier grégorien, il a eu un effet négatif sur la plupart des barrages, à l'exception du barrage de Bougous et barrage Bouhamdane, où il a eu un effet positif clair. Nous pouvons donc conclure que le calendrier grégorien n'est pas une variable d'entrée déterminante dans la plupart des cas.

---

## **Chapitre VI: Modélisation des Débits de Fuite par Les Modèles Neuroflous**

---

## VI.1. Introduction

Dans le présent chapitre, nous allons présenter et discuter les résultats détaillés de deux modèles ANFIS appelés ANFIS\_SC et ANFIS\_FC, ainsi que de leurs performances tout au long des phases d'apprentissage et de validation. La description théorique des deux modèles est déjà présentée en détail dans le Chapitre III. Les conclusions tirées de l'analyse des différents barrages: Bougous, Chaurfas, Zit Emba, Foum El Khanga et Hammam Debagh, mettent en évidence l'importance cruciale du choix des données d'entrée et de l'équilibre entre la complexité du modèle et sa capacité de généralisation. Les deux modèles ANFIS\_SC et ANFIS\_FC, sont basées sur la logique floue et les réseaux neuronaux, ouvrent la voie à une nouvelle perspective.

## VI.2. Mise En Œuvre du modèle ANFIS sous Matlab

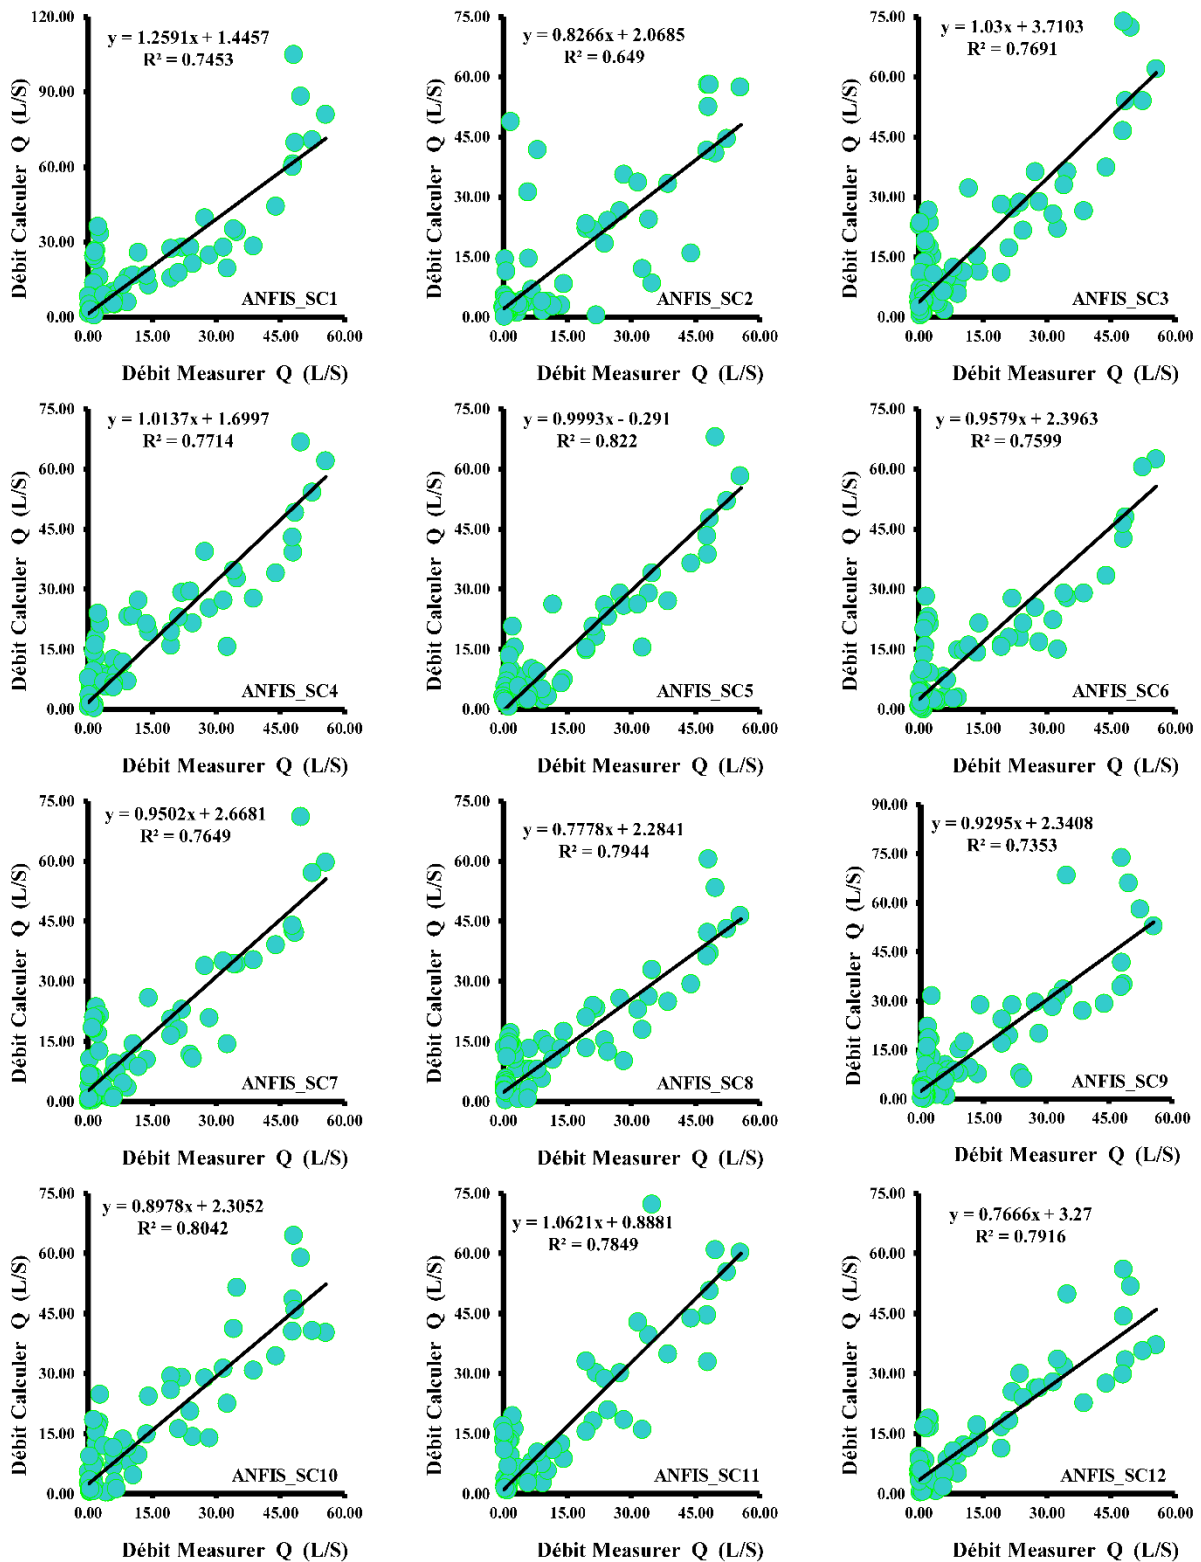
L'intégration du Système ANFIS avec des techniques de regroupement (clustering), spécifiquement la méthode des Centres Flous (FC) et la méthode de regroupement par soustraction (SC), se manifeste comme une approche puissante pour prédire les systèmes complexes non linéaires, particulièrement prévalent en hydrologie. Nous de manière exhaustive la méthodologie pour mettre en œuvre ces modèles ANFIS intégrés, on utilise Matlab, une plateforme de renommée pour le calcul numérique de haut niveau. L'impératif initial réside dans une préparation minutieuse des données, une étape fondamentale dans le processus de modélisation. L'aptitude de Matlab à la gestion et au prétraitement des données est exploitée à cette fin. L'intégration des modèles ANFIS avec des techniques de regroupement, mise en œuvre dans Matlab, met en avant les avantages synergiques de la combinaison de la logique floue avec les réseaux neuronaux. Cette fusion aboutit à des modèles prédictifs robustes, particulièrement avantageux pour les systèmes complexes tels que les phénomènes hydrologiques caractérisés par des non-linéarités et des incertitudes. Alors que les commandes Matlab fournies posent les bases du cadre, une personnalisation adaptée à des ensembles de données spécifiques et des objectifs de recherche est essentielle.

## VI.3. Résultats Obtenus par les modèles Neuroflous: Barrage Bougous

Pour la structure des modèles, on garde la même structure présentée dans le chapitre précédent avec en total douze modèles. Le **Tableau VI.1** présente les résultats des modèles au niveau du barrage Bougous. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents modèles Neuroflous sont reportés dans les **Figure VI.1-2**. En phase d'apprentissage, il est clair que les douze modèles ont affiché d'excellentes performances, dépassant tous un coefficient de corrélation ( $R$ ) de 0.930. ANFIS\_SC1 se distingue par des corrélations robustes avec une valeur  $R$  de 0.973 et un indice NSE de 0.946. Cependant, les mesures d'erreur, caractérisées par une RMSE de 3.805 et une MAE de 2.588, accusent un léger retard par rapport à certains autres modèles en termes de précision. Le modèle phare de cette analyse est ANFIS\_SC2, qui atteint une valeur  $R$  parfaite de 0.999 et présente des erreurs minimales, avec une RMSE et une MAE de 0.00. Cela suggère que ce modèle s'ajuste idéalement aux données d'apprentissage. En examinant d'autres métriques de performance,

telles que le NSE, le modèle ANFIS\_SC3 présente une valeur R notable de 0.965 et un NSE de 0.932. En comparaison avec ANFIS\_SC1, ANFIS\_SC4 offre des métriques similaires mais avec une légère amélioration de la précision. Par ailleurs, ANFIS\_SC5 se distingue comme un concurrent équilibré, se situant entre les performances d'ANFIS\_SC3 et d'ANFIS\_SC4. ANFIS\_SC6 conserve une puissance prédictive louable, bien qu'avec une légère baisse de performance, comme en témoignent sa valeur R de 0.951 et un NSE de 0.905. Une RMSE de 5.061 et une MAE de 3.493 illustrent davantage cette réduction. ANFIS\_SC7 reflète étroitement cette performance, avec une légère baisse de son indicateur d'efficacité et une augmentation de ses mesures d'erreur. Un déclin plus marqué est observé pour ANFIS\_SC8, mis en évidence par ses valeurs élevées de RMSE et MAE, i.e., 5.545 et 3.933, respectivement, traduisant des divergences notables par rapport aux observations actuelles. ANFIS\_SC9 et ANFIS\_SC10 gravitent autour de niveaux de performance analogues, bien que ce dernier présente des valeurs de RMSE et MAE plus élevées, suggérant des écarts plus marqués ou plus fréquents.

En phase de validation, l'analyse des valeurs R, NSE, RMSE et MAE de chaque modèle durant cette nous permet de distinguer leur précision et leur cohérence dans la prédiction de données inconnues. Les performances en validation offrent souvent une perspective plus pragmatique de l'efficacité d'un modèle dans des situations réelles. Se démarquant particulièrement lors de la phase de validation, le modèle ANFIS\_SC5 a démontré une corrélation robuste entre les valeurs prédites et observées, illustrée par un R de 0.907. Il a également surpassé la plupart des autres modèles avec un NSE de 0.783, traduisant des prédictions précises par rapport à la moyenne des données observées. En outre, les valeurs de RMSE et MAE pour ANFIS\_SC5 se sont établies à 7.591 et 5.390 respectivement, indiquant une déviation minimale par rapport aux observations réelles. Des modèles tels qu'ANFIS\_SC8, ANFIS\_SC10 et ANFIS\_SC12 méritent également d'être mentionnés. Leurs valeurs de NSE respectives de 0.793, 0.789 et 0.790 témoignent d'une précision solide dans les prédictions. Ce qui suscite l'intérêt concernant ces modèles est leur structure d'entrée simplifiée, mettant l'accent sur certaines données piézométriques conjointement avec la date calendaire et le niveau d'eau dans le réservoir (CPE). Par exemple, ANFIS\_SC8 et ANFIS\_SC10, en se basant respectivement sur les données PZ1 et PZ3, soulignent l'importance potentielle de ces piézomètres. Il est important de noter les performances d'ANFIS\_SC2 qui bien que ses métriques d'apprentissage étaient inégalées, n'a pas réussi à maintenir cet avantage lors de la validation. Avec un R de 0.806, un NSE de 0.600, une RMSE de 10.314 et une MAE de 5.912, il a été surpassé par plusieurs autres modèles. Les autres modèles, à savoir ANFIS\_SC3, ANFIS\_SC4, ANFIS\_SC6, ANFIS\_SC7, ANFIS\_SC9 et ANFIS\_SC11, ont présenté un éventail de performances, mais ont été en grande partie éclipsés par les modèles mentionnés précédemment. Par exemple, bien qu'ANFIS\_SC3 et ANFIS\_SC4 aient tous deux affiché des valeurs de R supérieures à 0.870, leurs valeurs de RMSE et MAE, étaient autour de 10 et 6 respectivement, suggèrent une marge d'amélioration en termes de précision des prédictions. La phase de validation met en lumière les nuances et subtilités des capacités prédictives de chaque modèle. Tandis que certains modèles, comme ANFIS\_SC5, brillent par une performance équilibrée, d'autres, malgré leur complexité ou leur large gamme de variables d'entrée, pourraient ne pas performer aussi bien.



**Figure VI. 1.** Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS\_SC: barrage Bougous & phase de validation.

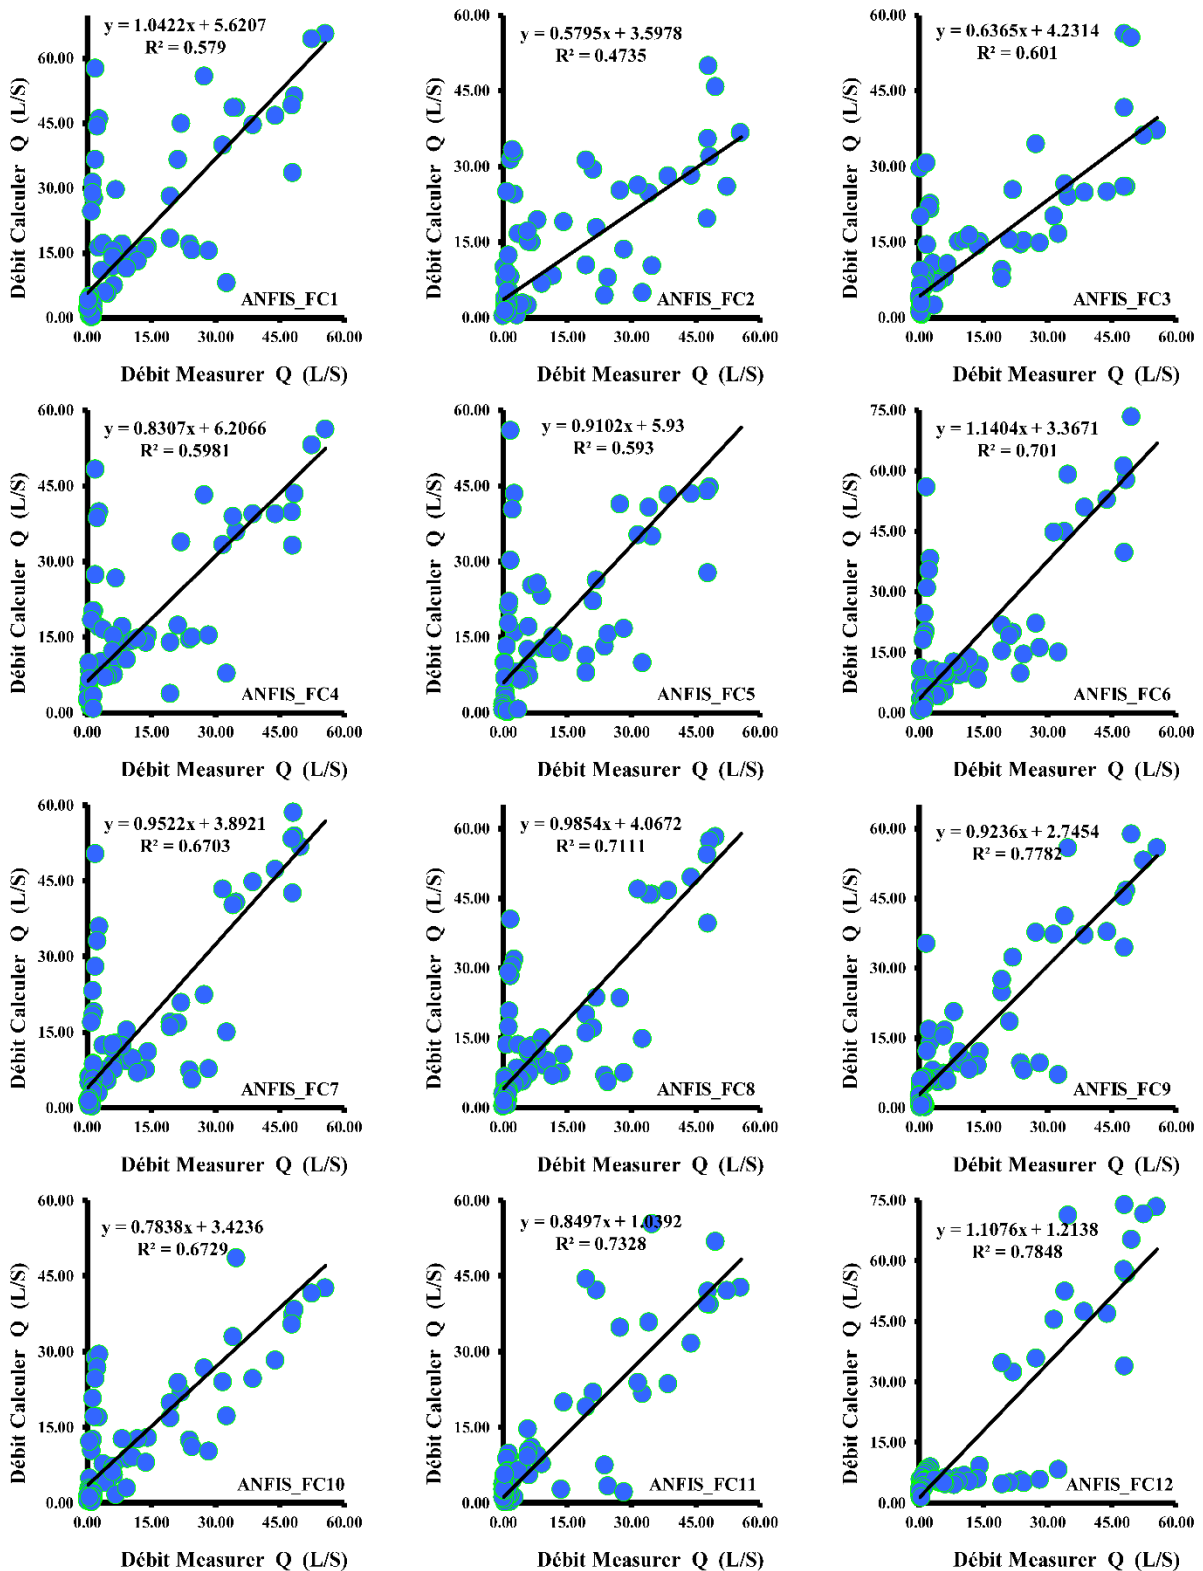


Figure VI. 2. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS\_FC: barrage Bougous & phase de validation.

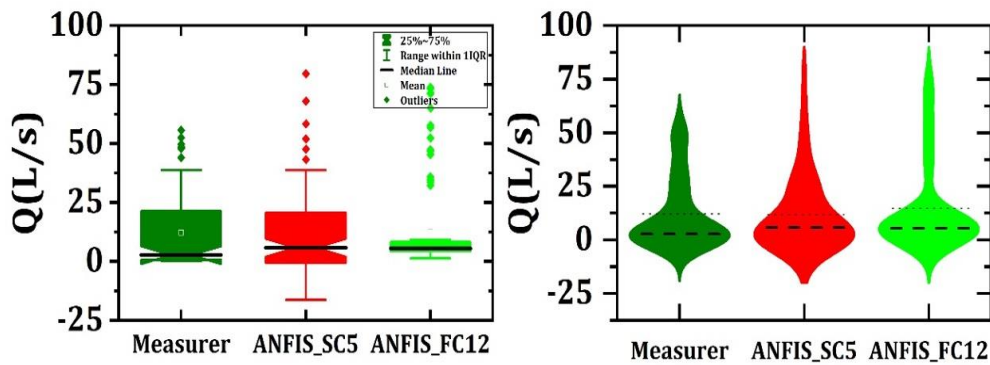
**Tableau VI. 1.** Performances des différents modèles Neuroflous & barrage Bougous.

| Models     | Training |       |       |       | Validation |       |        |        |
|------------|----------|-------|-------|-------|------------|-------|--------|--------|
|            | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE   | MAE    |
| ANFIS_SC1  | 0.973    | 0.946 | 3.805 | 2.588 | 0.863      | 0.311 | 13.537 | 9.048  |
| ANFIS_SC2  | 0.999    | 0.999 | 0.000 | 0.000 | 0.806      | 0.600 | 10.314 | 5.912  |
| ANFIS_SC3  | 0.965    | 0.932 | 4.279 | 3.023 | 0.877      | 0.618 | 10.079 | 6.928  |
| ANFIS_SC4  | 0.971    | 0.943 | 3.895 | 2.613 | 0.878      | 0.682 | 9.197  | 6.803  |
| ANFIS_SC5  | 0.967    | 0.935 | 4.188 | 2.884 | 0.907      | 0.783 | 7.591  | 5.390  |
| ANFIS_SC6  | 0.951    | 0.905 | 5.061 | 3.493 | 0.872      | 0.695 | 9.011  | 5.900  |
| ANFIS_SC7  | 0.948    | 0.900 | 5.190 | 3.460 | 0.875      | 0.704 | 8.874  | 5.799  |
| ANFIS_SC8  | 0.941    | 0.885 | 5.545 | 3.933 | 0.891      | 0.793 | 7.417  | 5.743  |
| ANFIS_SC9  | 0.946    | 0.896 | 5.294 | 3.535 | 0.858      | 0.676 | 9.289  | 6.058  |
| ANFIS_SC10 | 0.945    | 0.892 | 5.375 | 3.800 | 0.897      | 0.789 | 7.493  | 5.634  |
| ANFIS_SC11 | 0.956    | 0.914 | 4.798 | 3.419 | 0.886      | 0.677 | 9.274  | 6.240  |
| ANFIS_SC12 | 0.936    | 0.876 | 5.770 | 4.065 | 0.890      | 0.790 | 7.473  | 5.180  |
| ANFIS_FC1  | 0.917    | 0.841 | 6.527 | 4.488 | 0.761      | 0.067 | 15.757 | 10.292 |
| ANFIS_FC2  | 0.816    | 0.666 | 9.467 | 6.694 | 0.688      | 0.441 | 12.197 | 8.956  |
| ANFIS_FC3  | 0.900    | 0.810 | 7.145 | 5.226 | 0.775      | 0.599 | 10.334 | 7.785  |
| ANFIS_FC4  | 0.892    | 0.796 | 7.404 | 5.295 | 0.773      | 0.443 | 12.175 | 7.894  |
| ANFIS_FC5  | 0.902    | 0.813 | 7.079 | 5.121 | 0.770      | 0.336 | 13.297 | 8.401  |
| ANFIS_FC6  | 0.956    | 0.915 | 4.789 | 3.253 | 0.837      | 0.329 | 13.367 | 8.486  |
| ANFIS_FC7  | 0.948    | 0.899 | 5.217 | 3.557 | 0.819      | 0.511 | 11.414 | 7.422  |
| ANFIS_FC8  | 0.946    | 0.895 | 5.297 | 3.557 | 0.843      | 0.548 | 10.963 | 7.296  |
| ANFIS_FC9  | 0.954    | 0.909 | 4.929 | 3.603 | 0.882      | 0.739 | 8.341  | 5.360  |
| ANFIS_FC10 | 0.918    | 0.842 | 6.509 | 4.394 | 0.820      | 0.652 | 9.619  | 6.298  |
| ANFIS_FC11 | 0.931    | 0.867 | 5.965 | 4.027 | 0.856      | 0.712 | 8.758  | 6.224  |
| ANFIS_FC12 | 0.929    | 0.863 | 6.067 | 3.911 | 0.886      | 0.628 | 9.950  | 7.057  |


Les résultats obtenus par les divers modèles Neuroflous pour le barrage Bougous permettent de tirer les conclusions suivantes:

- 1) Les modèles ANFIS\_SC a régulièrement affiché d'excellentes performances lors des phases d'apprentissage et de validation, ce qui témoigne de leur capacité à élucider la dynamique de l'infiltration du barrage Bougous et à maintenir une cohérence entre diverses combinaisons d'entrées. En revanche, l'approche ANFIS\_FC a montré une variabilité de performance, suggérant sa sensibilité aux caractéristiques d'entrée sélectionnées, avec certaines configurations obtenant des résultats remarquables tandis que d'autres étaient moins performantes.
- 2) L'analyse de l'impact des données piézométriques révèle que les modèles tels que M1, M2 et M3, qui exploitent l'ensemble des points piézométriques, présentent généralement des performances solides. En contraste, bien que la gamme de modèles de M4 à M12 réduise progressivement le nombre de points piézométriques utilisés, cette réduction ne

- se traduit pas systématiquement par une diminution de la performance. À titre d'exemple, le modèle M8, qui repose exclusivement sur le point piézométrique PZ1 combiné avec des données du calendrier grégorien et la CPE, excelle par rapport à M3.
- 3) Dans les deux méthodologies, il a été observé que l'omission des variables d'entrée liées au calendrier grégorien avait un impact significatif sur la performance du groupe N°2 par rapport au groupe N°1.
  - 4) L'exclusion de la variable d'entrée correspondant au niveau d'eau du réservoir a entraîné une diminution notable de la performance dans le groupe N°3. En revanche, l'utilisation exclusive de variables d'entrée associées à la fois au niveau d'eau du réservoir et au calendrier grégorien dans le groupe N°12 a nettement surpassé les autres groupes en termes de performance.
  - 5) L'utilisation d'un unique piézomètre dans les configurations 8 à 11, variant en fonction de son emplacement, a donné lieu à des résultats de performance différents.
  - 6) Finalement, une comparaison graphique entre les meilleurs modèles est traduite par les deux **Figures VI.3** et **VI.4**.



**Figure VI. 3.** Comparaison entre les différents modèles Neuroflous par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Bougouss.



**Figure VI. 4.** Le diagramme de Taylor pour la comparaison entre les meilleurs modèles Neuroflous: Barrage Bougouss.

## V.4. Résultats Obtenus par les modèles Neuroflous: Barrage Cheurfas

Les résultats obtenus avec les modèles Neuroflous pour le barrage Cheurfas sont reportés dans le **Tableau VI. 2**. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents modèles Neuroflous sont reportés dans les **Figure VI.5-6**. En phase d'apprentissage, tous les modèles ont affiché des performances exceptionnelles caractérisées par un coefficient de corrélation ( $R$ ) et un indice NSE de 0.999, témoignant d'une adaptation parfaite aux données. Les mesures d'erreur de prédiction évaluées à l'aide du RMSE et du MAE Étaient pratiquement égale à zéro, ce qui atteste d'une prédiction du débit de fuite sans faille. Lors de la phase de validation, nous avons observé une variabilité des performances parmi les différents modèles ANFIS\_SC. ANFIS\_SC4 s'est distingué avec  $R=0.937$ ,  $NSE=0.837$ ,  $RMSE=0.651$  et un  $MAE=0.482$ , illustrant une précision élevée dans ses prédictions. En comparaison, ANFIS\_SC2 a affiché des performances inférieures, avec des métriques  $R$ ,  $NSE$ ,  $RMSE$  et  $MAE$  respectivement égales à 0.828, 0.630, 1.116 et 0.629. ANFIS\_SC3 a affiché des performances intermédiaires avec des valeurs de  $R$ ,  $NSE$ ,  $RMSE$  et  $MAE$  respectivement égales à 0.858, 0.734, 0.946 et 0.697. Les modèles ANFIS\_SC1, ANFIS\_SC5 et ANFIS\_SC11 ont montré des métriques similaires, se révélant être des concurrents sérieux pour ANFIS\_SC4 en termes de performance, avec des valeurs de  $R$  comprises entre 0.929 et 0.931, des  $NSE$  entre 0.855 et 0.862, des  $RMSE$  entre 0.682 et 0.699, et des  $MAE$  entre 0.473 et 0.515. Néanmoins. ANFIS\_SC6 a également obtenu des performances honorables, avec un  $R$  de 0.911, un  $NSE$  de 0.824, un  $RMSE$  de 0.770 et un  $MAE$  de 0.546. Cependant, les modèles ANFIS\_SC7 à ANFIS\_SC10 et ANFIS\_SC12, bien qu'ayant présenté des performances adéquates, étaient légèrement inférieurs à ceux des modèles précédents, avec des métriques  $R$ ,  $NSE$ ,  $RMSE$  et  $MAE$ , respectivement évaluées entre 0.889 et 0.891, entre 0.788 et 0.793, entre 0.636 et 0.645, et entre 0.543 et 0.575. Dans l'ensemble, les ANFIS\_SC1, ANFIS\_SC4, ANFIS\_SC5 et ANFIS\_SC11 se sont distingués lors de la phase de validation, indiquant un meilleur ajustement aux données observées et une erreur de prédiction réduite. En revanche, ANFIS\_SC2 a présenté des performances inférieures par rapport aux autres modèles. En conclusion, bien que les modèles ANFIS\_SC ait démontré leur efficacité dans la prédiction du débit d'infiltration, il est recommandé d'effectuer une évaluation approfondie pour sélectionner le modèle optimal dans le cadre d'applications concrètes.

Les modèles ANFIS\_FC1 à ANFIS\_FC12 présentés dans le **Tableau VI.2** ont été évalués pour leur efficacité lors des phases d'apprentissage et de validation. Pendant la phase d'apprentissage, ces modèles ont généralement affiché des performances notables, Plus précisément, les coefficients  $R$  se situaient dans une fourchette de 0.871 à 0.962, tandis que les valeurs de l'indice  $NSE$  variaient de 0.758 à 0.926. En outre, les valeurs de  $RMSE$  étaient comprises entre 0.592 et 1.071, tandis que  $MAE$  oscillait entre 0.447 et 0.825. Ces données indiquent une précision modérée des modèles pour la prédiction du débit de fuite au cours de cette phase. Parmi ces modèles, ANFIS\_FC4 s'est distingué en affichant un  $R$  de 0.962, un  $NSE$  de 0.926, un  $RMSE$  de 0.592 et un  $MAE$  de 0.447, témoignant de sa supériorité en termes de précision prédictive. En outre, ANFIS\_FC6 a également enregistré des performances remarquables avec un  $R$  de 0.953, un  $NSE$  de 0.908, un  $RMSE$  de 0.662 et un  $MAE$  de 0.519, ce qui le positionne comme l'un des modèles les plus efficaces.

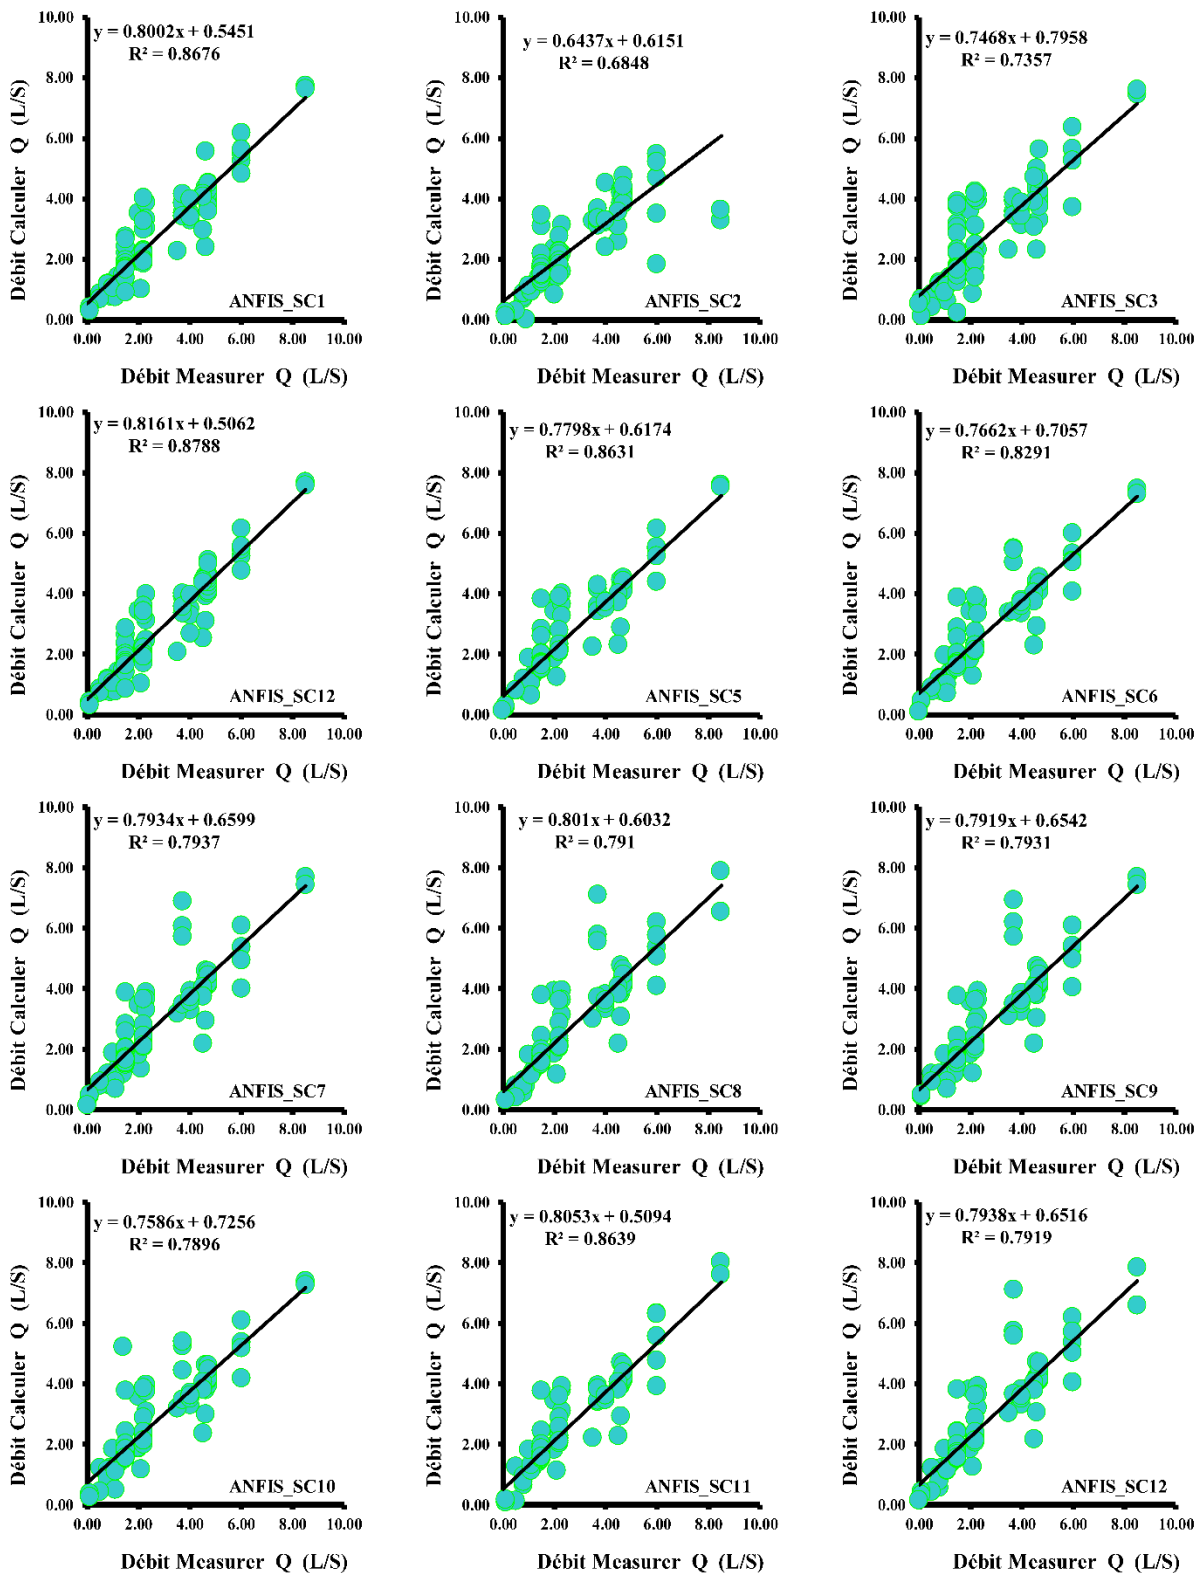


Figure VI. 5. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS\_SC: barrage Cheurfas & phase de validation.

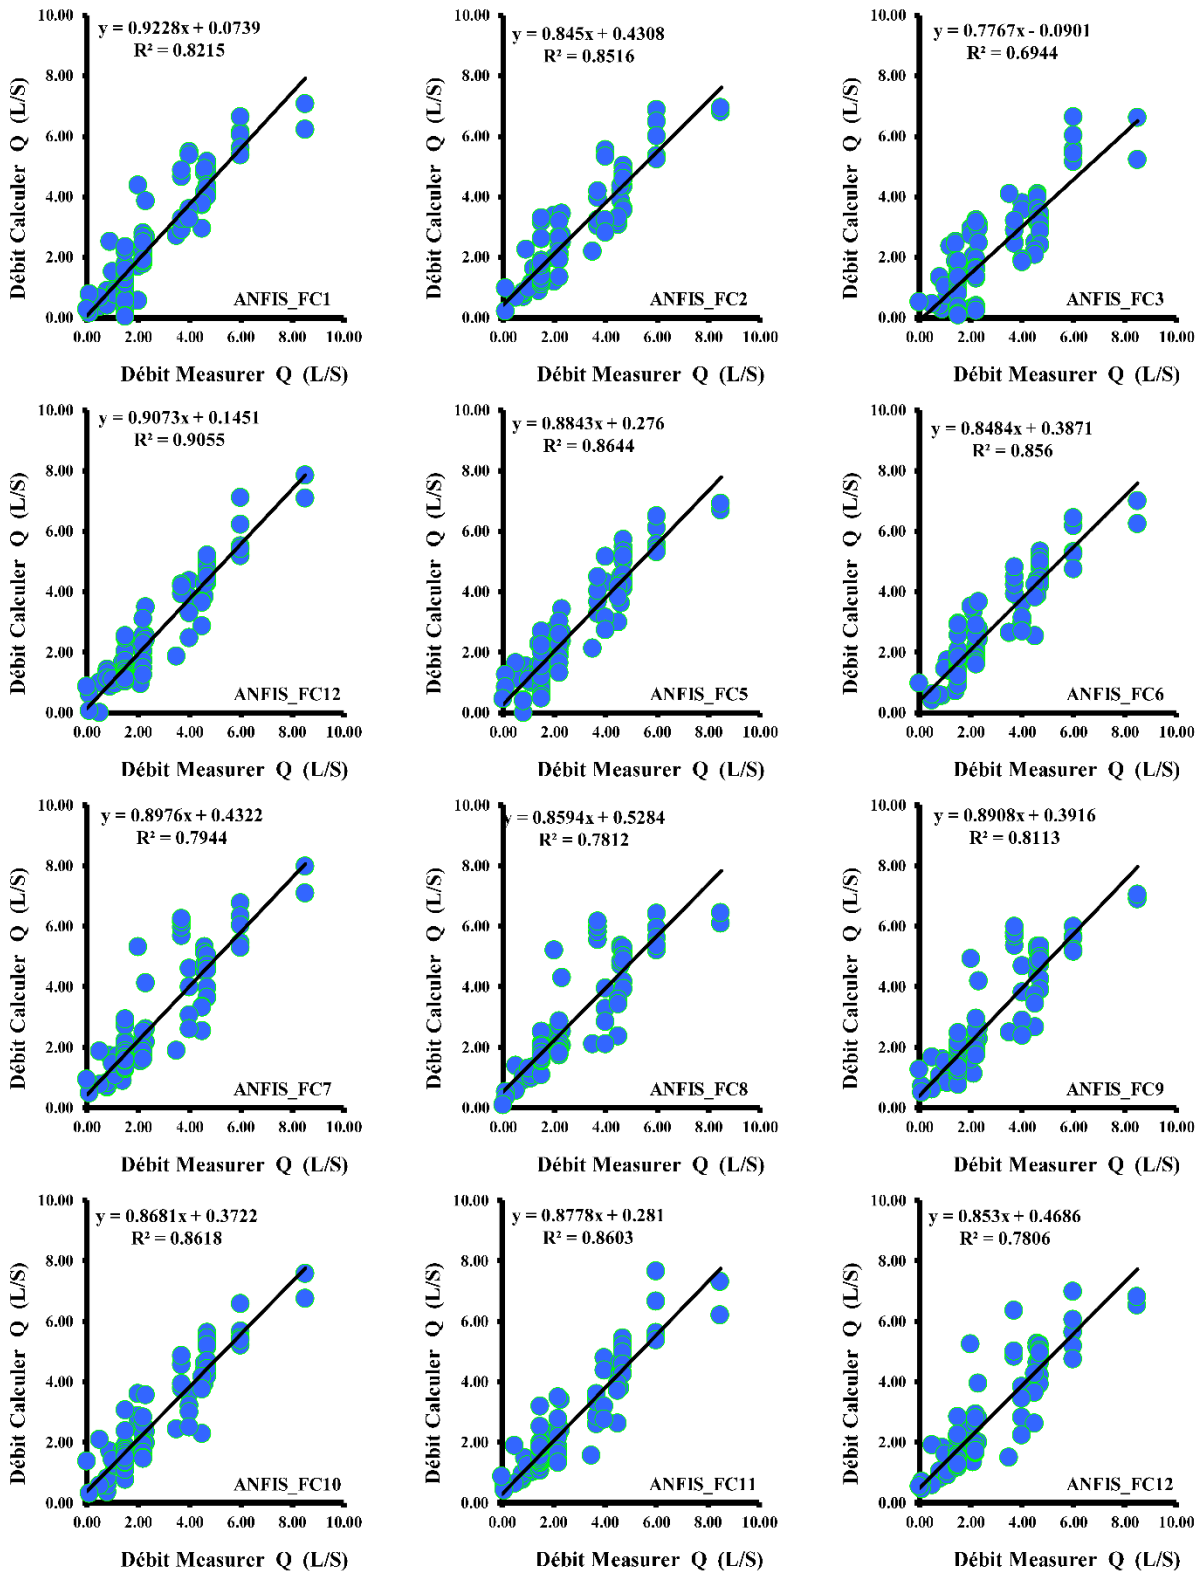


Figure VI. 6. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS\_FC: barrage Cheurfas & phase de validation.

Les modèles ANFIS\_FC5, ANFIS\_FC10 et ANFIS\_FC11 ont également démontré des performances solides avec des valeurs de R comprises entre 0.939 et 0.942, des NSE entre 0.886 et 0.887, et des valeurs de RMSE et MAE relativement proches de celles d'ANFIS\_FC4, soulignant leur capacité à prévoir le débit de fuite avec précision. En revanche, ANFIS\_FC3 a montré des performances moindres, caractérisées par des valeurs de R, NSE, RMSE et MAE respectives de 0.871, 0.758, 1.071 et 0.825, le plaçant ainsi parmi les modèles les moins efficaces de cet ensemble. Finalement, concernant les modèles ANFIS\_FC1, ANFIS\_FC2, ANFIS\_FC7, ANFIS\_FC8, ANFIS\_FC9 et ANFIS\_FC12, leurs performances se situaient à un niveau intermédiaire. Bien qu'ils n'aient pas atteint le niveau d'efficacité des modèles phares, ils ont tout de même démontré une capacité modérée à prédire le débit de fuite, ce qui les rend pertinents pour cette étude.

**Tableau VI. 2.** Performances des différent modèles Neuroflous & barrage Cheurfas.

| Models     | Training |       |       |       | Validation |       |       |       |
|------------|----------|-------|-------|-------|------------|-------|-------|-------|
|            | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE  | MAE   |
| ANFIS_SC1  | 0.999    | 0.999 | 0.000 | 0.000 | 0.931      | 0.862 | 0.682 | 0.514 |
| ANFIS_SC2  | 0.961    | 0.923 | 0.606 | 0.332 | 0.828      | 0.630 | 1.116 | 0.629 |
| ANFIS_SC3  | 0.999    | 0.999 | 0.000 | 0.000 | 0.858      | 0.734 | 0.946 | 0.697 |
| ANFIS_SC4  | 0.999    | 0.999 | 0.000 | 0.000 | 0.937      | 0.874 | 0.651 | 0.482 |
| ANFIS_SC5  | 0.999    | 0.999 | 0.000 | 0.000 | 0.929      | 0.855 | 0.699 | 0.494 |
| ANFIS_SC6  | 0.999    | 0.999 | 0.000 | 0.000 | 0.911      | 0.824 | 0.770 | 0.546 |
| ANFIS_SC7  | 0.999    | 0.999 | 0.000 | 0.000 | 0.891      | 0.793 | 0.836 | 0.557 |
| ANFIS_SC8  | 0.999    | 0.999 | 0.000 | 0.000 | 0.889      | 0.791 | 0.840 | 0.543 |
| ANFIS_SC9  | 0.999    | 0.999 | 0.000 | 0.000 | 0.891      | 0.792 | 0.836 | 0.572 |
| ANFIS_SC10 | 0.999    | 0.999 | 0.000 | 0.000 | 0.889      | 0.788 | 0.845 | 0.575 |
| ANFIS_SC11 | 0.999    | 0.999 | 0.000 | 0.000 | 0.929      | 0.859 | 0.689 | 0.473 |
| ANFIS_SC12 | 0.999    | 0.999 | 0.000 | 0.000 | 0.890      | 0.791 | 0.839 | 0.540 |
| ANFIS_FC1  | 0.928    | 0.862 | 0.811 | 0.563 | 0.906      | 0.802 | 0.816 | 0.600 |
| ANFIS_FC2  | 0.896    | 0.802 | 0.969 | 0.673 | 0.923      | 0.851 | 0.707 | 0.511 |
| ANFIS_FC3  | 0.871    | 0.758 | 1.071 | 0.825 | 0.833      | 0.523 | 1.268 | 1.036 |
| ANFIS_FC4  | 0.962    | 0.926 | 0.592 | 0.447 | 0.952      | 0.901 | 0.578 | 0.445 |
| ANFIS_FC5  | 0.942    | 0.886 | 0.734 | 0.515 | 0.930      | 0.863 | 0.680 | 0.563 |
| ANFIS_FC6  | 0.953    | 0.908 | 0.662 | 0.519 | 0.925      | 0.855 | 0.699 | 0.549 |
| ANFIS_FC7  | 0.920    | 0.846 | 0.856 | 0.626 | 0.891      | 0.776 | 0.870 | 0.581 |
| ANFIS_FC8  | 0.931    | 0.867 | 0.796 | 0.564 | 0.884      | 0.769 | 0.882 | 0.584 |
| ANFIS_FC9  | 0.939    | 0.882 | 0.749 | 0.562 | 0.901      | 0.802 | 0.817 | 0.587 |
| ANFIS_FC10 | 0.942    | 0.887 | 0.734 | 0.560 | 0.928      | 0.862 | 0.683 | 0.510 |
| ANFIS_FC11 | 0.939    | 0.882 | 0.747 | 0.559 | 0.928      | 0.858 | 0.691 | 0.507 |
| ANFIS_FC12 | 0.932    | 0.869 | 0.790 | 0.569 | 0.884      | 0.773 | 0.874 | 0.591 |

Lors de la phase de validation, les modèles ANFIS\_FC ont révélé une gamme de performances. Par exemple, le modèle ANFIS\_FC1 a affiché un coefficient de corrélation R de 0.906 et un indice NSE de 0.802, accompagnés d'un RMSE de 0.816 et d'un MAE de 0.600,

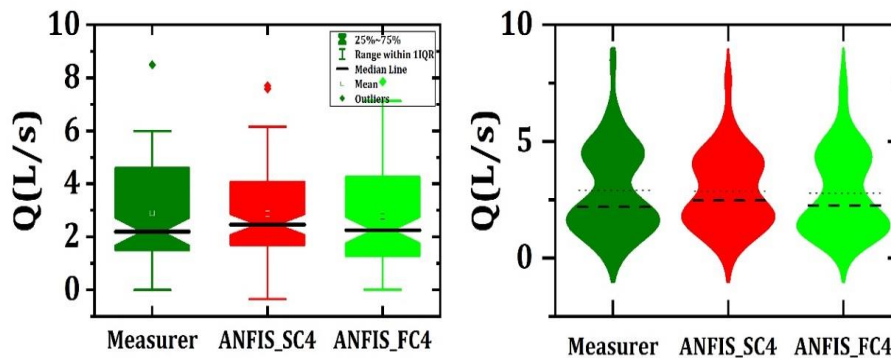
indiquant son bon ajustement aux données de validation. En revanche, ANFIS\_FC2 a obtenu de meilleures performances avec un R de 0.923 et un NSE de 0.851, ainsi que des valeurs de RMSE et MAE de 0.707 et 0.511, respectivement, démontrant une précision notable. À l'inverse, ANFIS\_FC3 a montré des performances inférieures caractérisées par un R de 0.833 et un NSE de 0.523, accompagnés des valeurs de RMSE et MAE atteignant respectivement les 1.268 et 1.036, indiquant des erreurs plus importantes. ANFIS\_FC4 a été distingué par son efficacité, enregistrant un R de 0.952, un NSE de 0.901, un RMSE de 0.578 et un MAE de 0.445, attestant ainsi de sa haute précision prédictive. Les modèles ANFIS\_FC5 à ANFIS\_FC7 ont affiché des performances homogènes, avec des R supérieurs à 0.900 et des NSE excédant 0.800. Ces résultats associés à des valeurs modérées des RMSE et MAE traduisent une bonne adéquation aux données de validation. En ce qui concerne ANFIS\_FC8 à ANFIS\_FC10, bien qu'efficaces leurs performances étaient légèrement inférieures par rapport aux modèles précédents avec des R excédant 0.880 et des NSE dépassant 0.760. ANFIS\_FC11 et ANFIS\_FC12 ont également montré une adéquation raisonnable avec des R supérieurs à 0.880 et des NSE excédant 0.770, malgré des valeurs de RMSE et MAE légèrement plus élevées. En synthèse, parmi tous les modèles, ANFIS\_FC4 s'est avéré être le plus performant lors de la phase de validation, caractérisé par son R élevé de 0.952 et son NSE de 0.901. En revanche, ANFIS\_FC3 a présenté les performances les moins satisfaisantes. Ces résultats suggèrent que l'intégration de différentes variables d'entrée telles que YY, MM, DD et les données des piézomètres pourrait avoir un impact significatif sur la précision des prédictions.

Les résultats obtenus par divers modèles Neuroflous pour le barrage Chaurfas Mascara permettent de tirer les conclusions suivantes:


- 1) Au cours des phases d'apprentissage, ANFIS\_SC affiche systématiquement des performances supérieures à celles d'ANFIS\_FC. De nombreux modèles ANFIS\_SC atteignent des valeurs optimales de coefficient de corrélation (R) et d'indice de Nash-Sutcliffe (NSE) de 0.999, tandis qu'ANFIS\_FC présente généralement des mesures légèrement inférieures. Cependant, lors de la phase de validation, l'écart de performance entre les deux approches se réduit. Par exemple, ANFIS\_SC1 affiche un R de validation de 0.931, tandis qu'ANFIS\_FC1 atteint un R de 0.906.
- 2) L'analyse des modèles sous ANFIS\_SC et ANFIS\_FC révèle que des performances optimales ne sont pas nécessairement liées au nombre d'entrées. Par exemple, bien que le modèle M1, qui inclut toutes les entrées, présente des résultats d'apprentissage excellents sous ANFIS\_SC, ses performances de validation ne sont pas nettement supérieures à celles de modèles tels que M12, qui utilise uniquement des dates et des CPE. Cela souligne l'importance de sélectionner des entrées pertinentes plutôt que d'augmenter leur nombre de manière indiscriminée.
- 3) L'inclusion ou l'exclusion des dates grégoriennes semble avoir des conséquences significatives. On observe une nette diminution des performances entre M1 et M2, où M2 exclut les dates, notamment dans la méthodologie ANFIS\_SC. Une tendance similaire se manifeste dans la stratégie ANFIS\_FC, mettant en évidence des différences

de performance en fonction de l'exclusion des dates. De telles observations pourraient suggérer que l'infiltration présente des tendances temporelles ou cycliques.

- 4) Le rôle des CPE est remarquable. Les modèles dépourvus de CPE, tels que M3, ont généralement affiché des performances inférieures à ceux qui les incluent, notamment M1 et M4. Cette disparité est particulièrement marquée dans la méthodologie ANFIS\_FC, soulignant l'importance du niveau d'eau dans le réservoir en tant que facteur prédictif.
- 5) Certains points piézométriques semblent exercer une influence plus marquée que d'autres. Par exemple, les modèles incorporant PZ4, comme M11, ont tendance à surpasser ceux qui dépendent uniquement de points piézométriques alternatifs tels que M8, M9 et M10, dans les deux méthodologies. Cela suggère que certains points piézométriques peuvent fournir des informations plus précieuses que d'autres.



**Figure VI. 7.** Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Cheurfas.



**Figure VI. 8.** Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles : Barrage Cheurfas.

### VI.5. Résultats Obtenus par les modèles Neuroflous: Barrage De Zit Emba

Les résultats obtenus avec les modèles Neuroflous pour le barrage Zit Emba sont reportés dans le **Tableau VI. 3**. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents modèles Neuroflous sont reportés dans les **Figure VI.9-10**. Tout d'abord, il est évident que tous les modèles ont démontré des performances exceptionnelles

pendant la phase d'apprentissage, atteignant un coefficient R et un NSE de 0.999, avec des valeurs de RMSE et de MAE égales à zéro pour tous les modèles. Cela suggère que les modèles ont appris de manière optimale à partir des données d'apprentissage. Dans cette phase, il est difficile de distinguer les modèles en termes de performance, à l'exception du modèle ANFIS\_SC2, qui a présenté des performances inférieures avec un coefficient R et un NSE différents des autres modèles, ce qui en fait le moins performant à cette étape.

**Tableau VI. 3.** Performances des différent modèles Neuroflous & barrage Zit Emba.

| Models     | Training |       |       |       | Validation |        |       |       |
|------------|----------|-------|-------|-------|------------|--------|-------|-------|
|            | R        | NSE   | RMSE  | MAE   | R          | NSE    | RMSE  | MAE   |
| ANFIS_SC1  | 1.000    | 1.000 | 0.000 | 0.000 | 0.824      | 0.642  | 1.035 | 0.823 |
| ANFIS_SC2  | 0.829    | 0.687 | 0.866 | 0.643 | 0.814      | 0.640  | 1.038 | 0.776 |
| ANFIS_SC3  | 1.000    | 1.000 | 0.000 | 0.000 | 0.819      | 0.633  | 1.048 | 0.833 |
| ANFIS_SC4  | 1.000    | 1.000 | 0.000 | 0.000 | 0.816      | 0.625  | 1.059 | 0.825 |
| ANFIS_SC5  | 1.000    | 1.000 | 0.000 | 0.000 | 0.815      | 0.625  | 1.059 | 0.833 |
| ANFIS_SC6  | 1.000    | 1.000 | 0.000 | 0.000 | 0.817      | 0.626  | 1.058 | 0.840 |
| ANFIS_SC7  | 1.000    | 1.000 | 0.000 | 0.000 | 0.826      | 0.644  | 1.032 | 0.836 |
| ANFIS_SC8  | 1.000    | 1.000 | 0.000 | 0.000 | 0.825      | 0.640  | 1.037 | 0.839 |
| ANFIS_SC9  | 1.000    | 1.000 | 0.000 | 0.000 | 0.823      | 0.640  | 1.038 | 0.835 |
| ANFIS_SC10 | 1.000    | 1.000 | 0.000 | 0.000 | 0.822      | 0.639  | 1.039 | 0.840 |
| ANFIS_SC11 | 1.000    | 1.000 | 0.000 | 0.000 | 0.822      | 0.637  | 1.042 | 0.846 |
| ANFIS_SC12 | 1.000    | 1.000 | 0.000 | 0.000 | 0.804      | 0.617  | 1.070 | 0.876 |
| ANFIS_FC1  | 0.842    | 0.709 | 0.835 | 0.608 | 0.830      | 0.603  | 1.090 | 0.877 |
| ANFIS_FC2  | 0.913    | 0.833 | 0.632 | 0.474 | 0.826      | 0.439  | 1.296 | 1.007 |
| ANFIS_FC3  | 0.832    | 0.692 | 0.858 | 0.629 | 0.855      | 0.639  | 1.039 | 0.850 |
| ANFIS_FC4  | 0.814    | 0.662 | 0.900 | 0.663 | 0.844      | 0.618  | 1.069 | 0.846 |
| ANFIS_FC5  | 0.906    | 0.820 | 0.656 | 0.500 | 0.841      | -0.357 | 2.015 | 1.417 |
| ANFIS_FC6  | 0.906    | 0.821 | 0.654 | 0.496 | 0.817      | 0.558  | 1.150 | 0.922 |
| ANFIS_FC7  | 0.837    | 0.700 | 0.847 | 0.646 | 0.851      | 0.698  | 0.951 | 0.757 |
| ANFIS_FC8  | 0.845    | 0.715 | 0.827 | 0.626 | 0.843      | 0.688  | 0.967 | 0.768 |
| ANFIS_FC9  | 0.839    | 0.704 | 0.841 | 0.637 | 0.811      | 0.639  | 1.039 | 0.827 |
| ANFIS_FC10 | 0.831    | 0.690 | 0.861 | 0.640 | 0.829      | 0.655  | 1.016 | 0.817 |
| ANFIS_FC11 | 0.844    | 0.713 | 0.830 | 0.607 | 0.833      | 0.654  | 1.017 | 0.829 |
| ANFIS_FC12 | 0.824    | 0.679 | 0.877 | 0.657 | 0.839      | 0.680  | 0.979 | 0.784 |

En phase de validation le modèle ANFIS\_SC1 se démarque avec un coefficient de corrélation (R) de 0.824, indiquant une forte corrélation entre les valeurs calculées et les valeurs mesurées. De plus, il présente un NSE de 0.642, témoignant d'une performance supérieure à un modèle simple basé sur la moyenne historique des valeurs. Les erreurs moyennes de ce modèle, mesurées par le RMSE et le MAE, sont respectivement de 1.035 et 0.823, ce qui indique des erreurs moyennes en comparaison avec les performances des autres modèles. En ce qui concerne le modèle ANFIS\_SC2, un coefficient de corrélation (R) de 0.814 et un NSE de 0.640 indiquent des performances légèrement inférieures à celles du modèle ANFIS\_SC1. Cependant, les erreurs moyennes de ce modèle sont légèrement supérieures à celles du modèle M1, avec un RMSE de 1.038 et un MAE de 0.776. Les modèles ANFIS\_SC3 à ANFIS\_SC6 présentent des performances similaires, avec un coefficient R variant entre 0.819 et 0.817, et un NSE entre 0.633 et 0.626. Les erreurs moyennes de ces modèles sont légèrement supérieures à celles des

modèles ANFIS\_SC1 et ANFIS\_SC2, avec un RMSE variant entre 1.048 et 1.058, et un MAE entre 0.833 et 0.840. Les modèles ANFIS\_SC7 à ANFIS\_SC9 affichent des performances supérieures par rapport aux autres modèles, avec un coefficient R entre 0.826 et 0.823, et un NSE entre 0.644 et 0.640. De plus, les erreurs moyennes de cette série de modèles sont inférieures, avec un RMSE variant entre 1.032 et 1.038, et un MAE entre 0.836 et 0.835.

Pour les modèles ANFIS\_SC10 à ANFIS\_SC11, ils enregistrent une valeur de R égale à 0.822 et un NSE varie entre 0.639 et 0.637. Cependant, les erreurs relatives dans ce groupe sont les plus élevées, avec un RMSE oscillant entre 1.039 et 1.042, et un MAE variant entre 0.840 et 0.835. Le modèle le moins performant est le modèle ANFIS\_SC12, ce dernier présente une performance moindre avec un R de 0.804 et un NSE de 0.617. De plus, il affiche la plus grande RMSE de 1.070 et MAE de 0.876, indiquant que l'exclusion de toutes les mesures piézométriques a eu un impact négatif sur la performance. Tous les modèles présentent des performances acceptables lors de la phase de validation. Cependant, il devient évident que le modèle ANFIS\_SC7 surpasse les autres en termes de performance pendant la phase de validation. Il atteint le coefficient  $R=0.826$ , un  $NSE=0.644$ , ainsi que les valeurs les plus basses de  $RMSE=1.032$  et de  $MAE=0.836$ .

Lors de la phase d'apprentissage, les modèles ANFIS\_FC ont affichés une diversité notable dans leurs performances. Pour commencer, le modèle ANFIS\_FC1 a révélé une corrélation louable, avec une valeur de R de 0.842 et un NSE de 0.709. Cependant, un RMSE de 0.835 et un MAE de 0.608 suggèrent des opportunités d'amélioration. En contraste marqué, ANFIS\_FC2 s'est avéré exceptionnel, avec un R robuste de 0.913 et un NSE inégalé de 0.833. Les valeurs de RMSE et de MAE pour ce modèle, étaient de 0.632 et 0.474 respectivement, parmi les plus optimales observées. ANFIS\_FC3 a présenté des performances modérées, illustrées par un R de 0.832 et un NSE de 0.692. Malgré cela, des valeurs de RMSE à 0.858 et MAE à 0.629 suggèrent des prédictions en adéquation avec les valeurs observées. ANFIS\_FC4, par contre, semblait légèrement en retrait avec une valeur de R de 0.814, un NSE de 0.662, un RMSE de 0.900 et un MAE de 0.663, Ceci le place derrière les modèles les plus performants en termes de précision. ANFIS\_FC5 et ANFIS\_FC6 ont affiché des performances solides, le premier avec un R de 0.906, un NSE de 0.820, un RMSE de 0.656 et un MAE de 0.500, le second avec des valeurs similaires de R et NSE, mais des RMSE et MAE légèrement meilleurs de l'ordre de 0.654 et 0.496, respectivement. Les modèles ANFIS\_FC7, ANFIS\_FC8 et ANFIS\_FC9 ont montré des performances comparables, chacun affichant un R et un NSE dans les gammes de 0.830 à 0.850 et de 0.700 à 0.715, avec des RMSE et MAE modérés. ANFIS\_FC10 et ANFIS\_FC11 ont également démontré une performance cohérente, avec des valeurs de R de 0.831 et 0.844, et des NSE de 0.690 et 0.713 respectivement. Enfin, ANFIS\_FC12 s'est positionné légèrement plus bas avec un R de 0.824, un NSE de 0.679, un RMSE de 0.877 et un MAE de 0.657. Il est notable que pendant cette phase, ANFIS\_FC2 s'est distingué comme le modèle le plus performant en termes d'indicateurs. Cette efficacité est probablement due aux paramètres d'entrée judicieusement sélectionnés axés sur les données piézométriques et le niveau d'eau dans le réservoir.

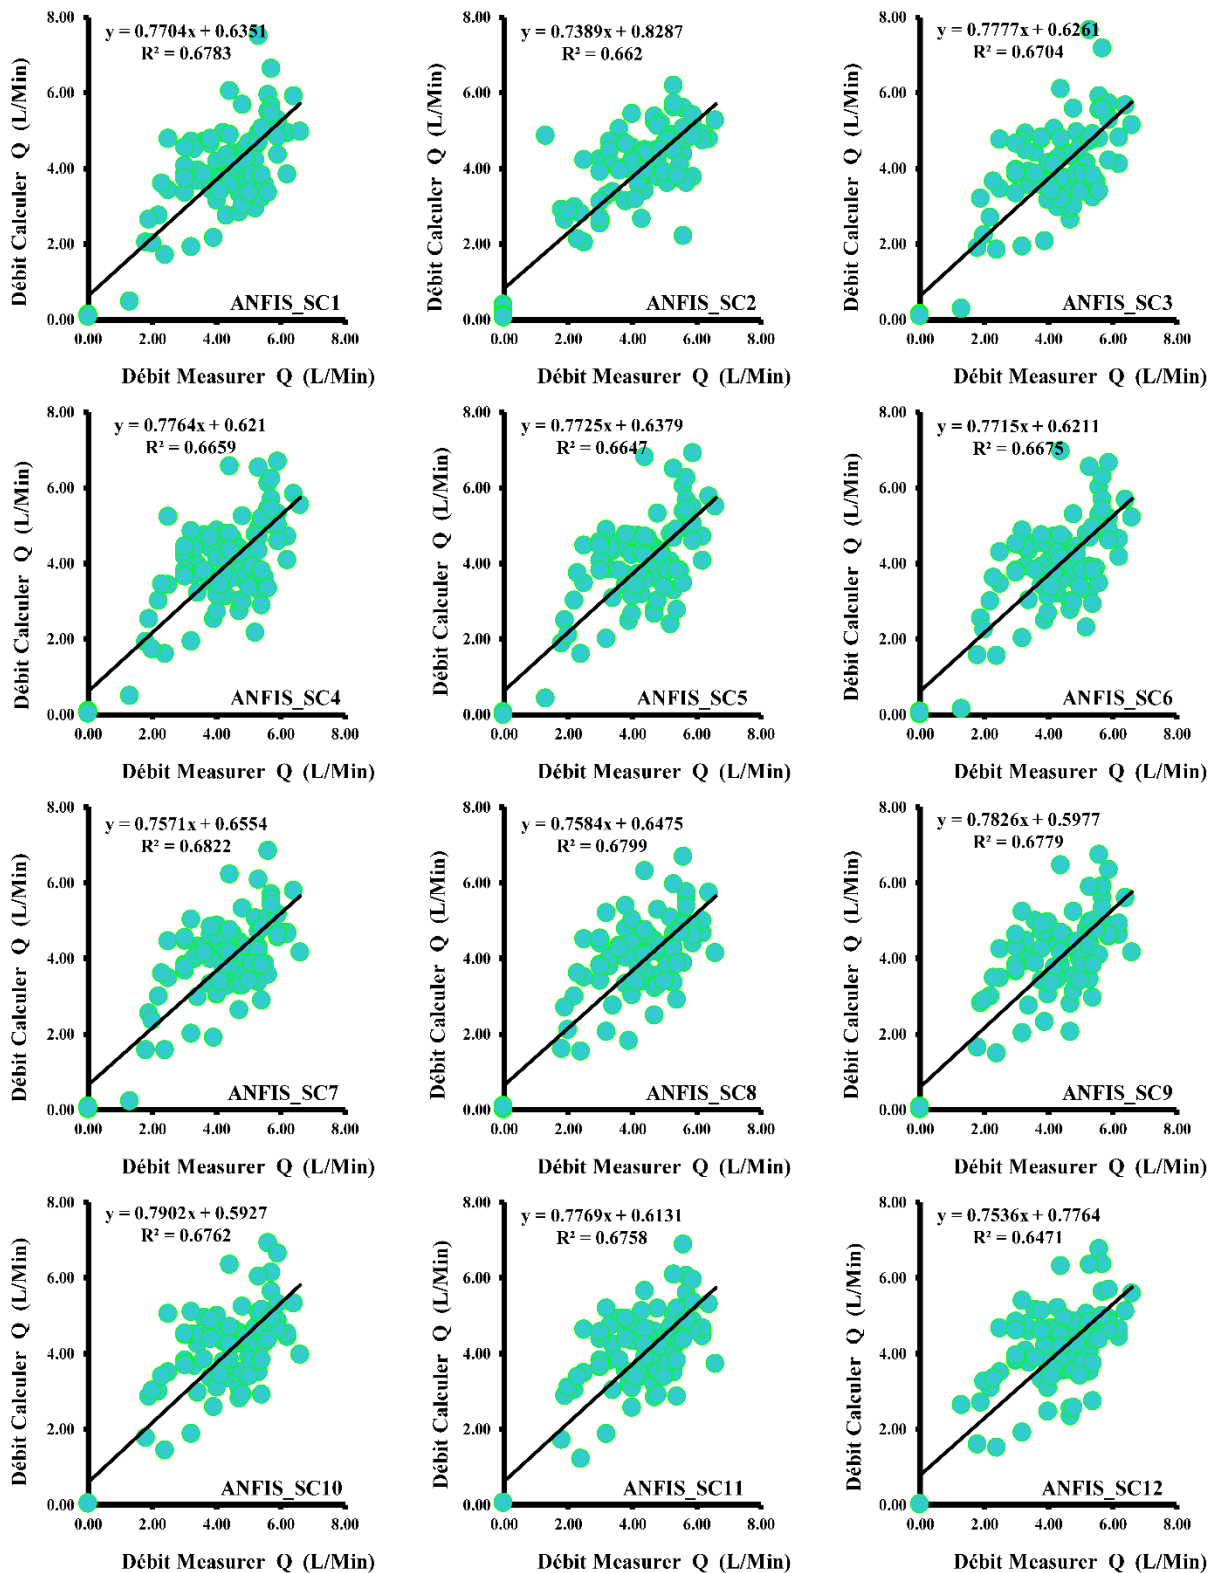


Figure VI. 9. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS\_SC : barrage Zit Emba & phase de validation.

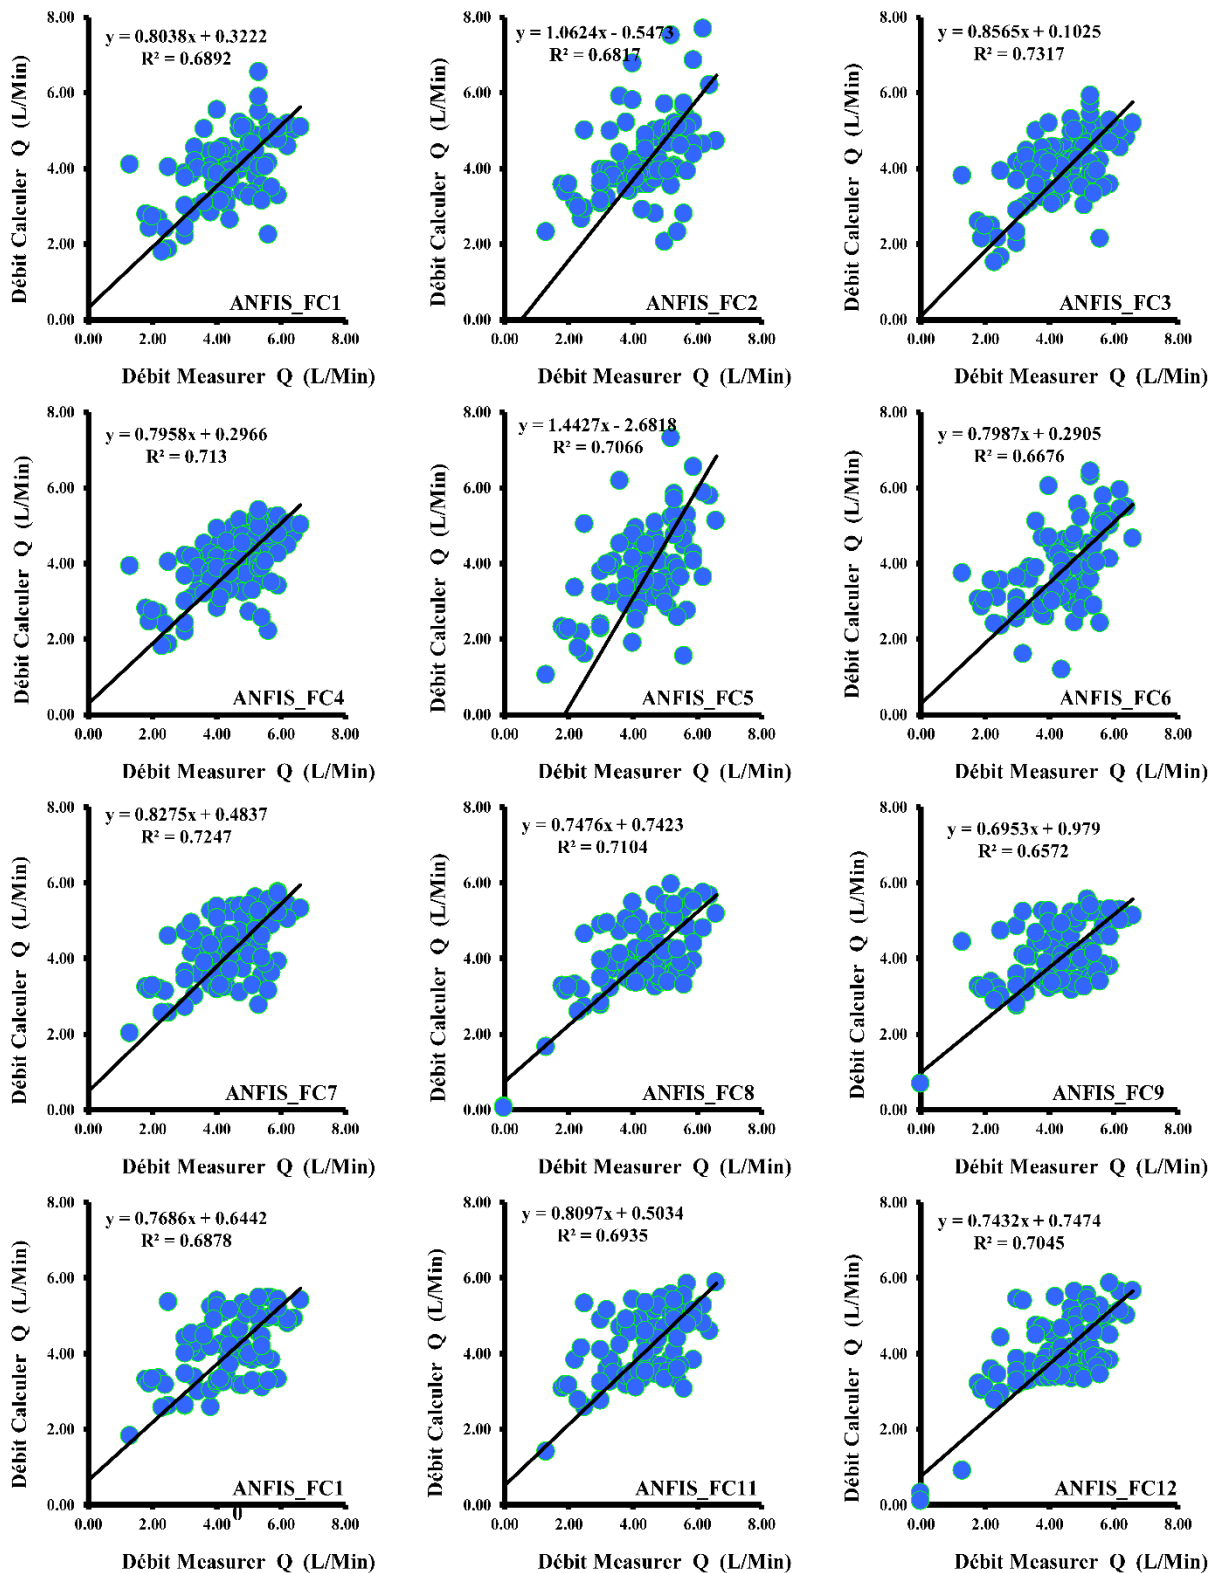


Figure VI. 10. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS\_FC : barrage Zit Emba & phase de validation.

Au cours de l'évaluation des performances durant la phase de validation, il a été observé que plusieurs modèles présentaient des variations significatives en termes de précision. Le modèle ANFIS\_FC3 a enregistré un coefficient R de 0.855, suggérant une forte corrélation avec les observations réelles. En contraste, ANFIS\_FC7 s'est distingué en affichant les indices les plus optimaux pour NSE avec une valeur de 0.698, le RMSE à 0.951 et le MAE à 0.757, témoignant d'une précision prédictive remarquable. De façon spécifique, ANFIS\_FC1, ANFIS\_FC2, ANFIS\_FC3 et ANFIS\_FC4 ont présenté des coefficients R de 0.830, 0.826, 0.855 et 0.844. Tandis que le NSE pour ces modèles variait de 0.603 à 0.618, les indices RMSE et MAE ont fluctué, avec des valeurs maximales de 1.296 et 1.007 pour ANFIS\_FC2, soulignant des écarts prédictifs possibles. Il convient de noter que ANFIS\_FC5 a affiché des performances largement insatisfaisantes avec un NSE négatif de -0,357, complété par des valeurs RMSE et MAE élevées de 2.015 et 1.417 respectivement. Quant aux modèles ANFIS\_FC6 à ANFIS\_FC12, leurs R variaient entre 0.817 et 0.839, et leurs indices d'erreurs (RMSE, MAE) ont indiqué des niveaux variables, allant de modéré à compétitif. La singularité de la performance d'ANFIS\_FC5 mérite une attention particulière. Malgré une valeur R convenable, son NSE négatif pourrait indiquer des problèmes potentiels de surajustement, soulignant la nécessité d'une évaluation plus approfondie.

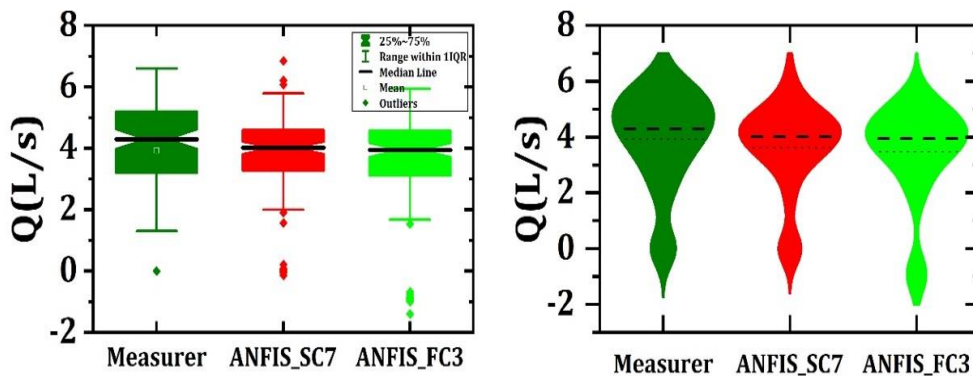
L'hétérogénéité observée parmi les modèles souligne l'importance des variables d'entrée. Le niveau d'eau dans le réservoir, désigné par CPE, s'est révélé être un prédicteur crucial, tandis que l'influence des données piézométriques dépendait des différents points de données. De plus, l'utilité du calendrier grégorien en tant que variable prédictive s'est avérée ambivalente. En conclusion, bien que les modèles ANFIS\_FC2 et ANFIS\_FC7 aient excellé durant les phases respectives d'apprentissage et de validation, il est impératif d'adopter une approche prudente pour éviter le surajustement. La robustesse, la généralisation et la résistance au surajustement du modèle sont assurées par un processus de sélection de modèle rigoureux, appuyé par des phases d'apprentissage et de validation. Les travaux ultérieurs pourraient bénéficier de l'utilisation de jeux de données de validation

Les résultats obtenus par divers modèles de système Neuroflous pour le barrage Zit Emba permettent de tirer les conclusions suivantes:

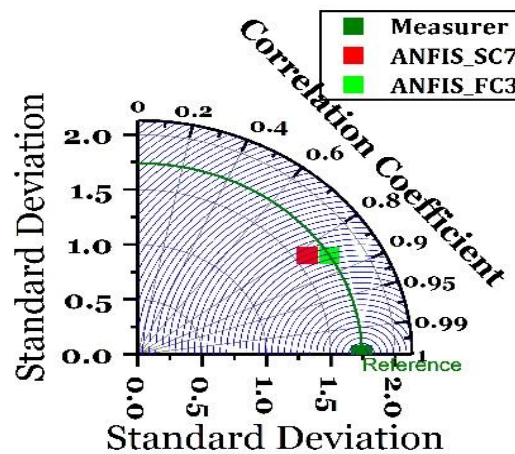
1. Compte tenu de la diversité de ses performances dans différentes combinaisons d'entrées, ANFIS\_FC pourrait être plus adapté aux applications pratiques. Sa capacité d'adaptation potentielle et sa moindre sensibilité au surajustement le rendent potentiellement plus avantageux que ANFIS\_SC.
2. Tous les modèles ANFIS\_SC présente des performances d'apprentissage optimales, quel que soit le nombre d'entrées, ce qui laisse entrevoir un éventuel surajustement. En revanche, les modèles ANFIS\_FC, de ANFIS\_FC1 à ANFIS\_FC12, n'affichent aucune tendance distincte dans les résultats d'apprentissage ou de validation, ce qui indique une résilience à diverses combinaisons d'entrées.
3. En comparant les modèles qui excluent les données de date, tels que M2, avec ceux qui les incluent, tels que M1, aucune disparité significative de performance n'est évidente.

Cela suggère que la date peut ne pas servir de prédicteur prédominant, ou que son influence peut être englobée par d'autres variables d'entrée.

4. L'exclusion séquentielle des points de données piézométriques des modèles, comme illustré de M1 à M12 avec le ANFIS\_SC, ne conduit pas à une divergence marquée dans les résultats de validation. Cette observation implique que la signification des points de données piézométriques individuels peut ne pas être uniforme.
5. Une comparaison entre les modèles qui excluent le niveau d'eau, comme M3, et ceux qui l'incluent, comme M1, ne révèle aucune disparité substantielle dans les résultats de validation. Cela suggère que le niveau d'eau peut ne pas servir de prédicteur dominant, ou que son impact pourrait être englobé par d'autres variables d'entrée.
6. Bien qu'une plus grande quantité d'entrées ne garantisse pas des performances améliorées, comme en témoignent les résultats de validation comparables de M1 à des modèles plus légers, la pertinence de ces entrées est primordiale. De plus, bien qu'une évaluation définitive nécessite une analyse plus approfondie, tous les points de données piézométriques n'ont pas le même poids, certaines combinaisons telles que la date et CPE pouvant fournir des informations distinctes au milieu de données piézométriques réduites.



**Figure VI. 11.** Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Zit Emba.



**Figure VI. 12.** Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles: Barrage Zit Emba.

## VI.6. Résultats Obtenus par les modèles Neuroflous : Barrage Foum el Khanga

Les résultats obtenus par les deux modèles Neuroflous au niveau du barrage Foum el Khanga sont reportés dans le tableau VI.4. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents modèles Neuroflous sont reportés dans les **Figure VI.13-14**.

**Tableau VI. 4.** Performances des différent modèles Neuroflous & barrage Foum el Khanga.

| Models     | Training |       |       |       | Validation |        |       |       |
|------------|----------|-------|-------|-------|------------|--------|-------|-------|
|            | R        | NSE   | RMSE  | MAE   | R          | NSE    | RMSE  | MAE   |
| ANFIS_SC1  | 0.999    | 0.999 | 0.000 | 0.000 | 0.545      | 0.012  | 0.186 | 0.119 |
| ANFIS_SC2  | 0.999    | 0.999 | 0.000 | 0.000 | 0.701      | 0.371  | 0.149 | 0.083 |
| ANFIS_SC3  | 0.999    | 0.999 | 0.000 | 0.000 | 0.463      | -0.114 | 0.198 | 0.128 |
| ANFIS_SC4  | 0.922    | 0.850 | 0.066 | 0.043 | 0.636      | -2.065 | 0.328 | 0.256 |
| ANFIS_SC5  | 0.854    | 0.729 | 0.089 | 0.061 | 0.640      | -0.028 | 0.190 | 0.137 |
| ANFIS_SC6  | 0.791    | 0.626 | 0.104 | 0.078 | 0.546      | -0.161 | 0.202 | 0.142 |
| ANFIS_SC7  | 0.852    | 0.726 | 0.089 | 0.068 | 0.577      | -0.817 | 0.253 | 0.180 |
| ANFIS_SC8  | 0.778    | 0.605 | 0.107 | 0.081 | 0.516      | -0.077 | 0.195 | 0.139 |
| ANFIS_SC9  | 0.777    | 0.603 | 0.107 | 0.077 | 0.611      | 0.244  | 0.163 | 0.119 |
| ANFIS_SC10 | 0.760    | 0.578 | 0.111 | 0.079 | 0.602      | 0.251  | 0.162 | 0.115 |
| ANFIS_SC11 | 0.758    | 0.574 | 0.111 | 0.079 | 0.634      | 0.339  | 0.152 | 0.111 |
| ANFIS_SC12 | 0.876    | 0.767 | 0.082 | 0.055 | 0.383      | -1.576 | 0.301 | 0.215 |
| ANFIS_FC1  | 0.706    | 0.499 | 0.121 | 0.086 | 0.543      | 0.210  | 0.167 | 0.134 |
| ANFIS_FC2  | 0.747    | 0.558 | 0.113 | 0.078 | 0.582      | 0.180  | 0.170 | 0.126 |
| ANFIS_FC3  | 0.663    | 0.440 | 0.127 | 0.091 | 0.439      | 0.116  | 0.176 | 0.140 |
| ANFIS_FC4  | 0.701    | 0.491 | 0.121 | 0.087 | 0.543      | 0.242  | 0.163 | 0.129 |
| ANFIS_FC5  | 0.809    | 0.654 | 0.100 | 0.070 | 0.567      | -0.084 | 0.195 | 0.140 |
| ANFIS_FC6  | 0.778    | 0.605 | 0.107 | 0.077 | 0.582      | 0.053  | 0.183 | 0.137 |
| ANFIS_FC7  | 0.819    | 0.670 | 0.098 | 0.062 | 0.619      | -0.189 | 0.204 | 0.149 |
| ANFIS_FC8  | 0.898    | 0.807 | 0.075 | 0.046 | 0.689      | -0.236 | 0.208 | 0.145 |
| ANFIS_FC9  | 0.838    | 0.703 | 0.093 | 0.069 | 0.658      | 0.160  | 0.172 | 0.130 |
| ANFIS_FC10 | 0.849    | 0.720 | 0.090 | 0.059 | 0.694      | 0.262  | 0.161 | 0.123 |
| ANFIS_FC11 | 0.820    | 0.672 | 0.097 | 0.070 | 0.651      | 0.161  | 0.172 | 0.125 |
| ANFIS_FC12 | 0.873    | 0.763 | 0.083 | 0.053 | 0.320      | -1.543 | 0.299 | 0.229 |

En phase d'apprentissage, parmi tous les modèles, ANFIS\_SC1, ANFIS\_SC2 et ANFIS\_SC3 se sont démarqués, affichant des performances exceptionnelles. Ces modèles ont atteint à la fois un coefficient R et un NSE de 0.999. De tels indicateurs suggèrent une compréhension parfaite des données d'apprentissage, sans laisser de traces de variance inexpliquée. De plus, les RMSE et MAE pour ces modèles étaient égales à 0.000, indiquant un alignement total entre les valeurs prédites et réelles. Au-delà de ce trio exemplaire, une diminution subséquente des indicateurs de performance a été constatée. À titre d'exemple, ANFIS\_SC4 a affiché un R de 0.922 et un NSE de 0.850, témoignant de corrélations robustes, bien que non parfaites. De plus, ANFIS\_SC5 et ANFIS\_SC7 ont montré des performances similaires avec des valeurs de R légèrement supérieures à 0.850 et des NSE approchant 0.725. Un groupe composé d'ANFIS\_SC6 à ANFIS\_SC11, bien qu'affichant des R satisfaisant variant de 0.760 à 0.791, a montré des divergences prédictives marquées. Au sein de ce groupe, le NSE variait entre 0.574 et 0.626, suggérant une notable variance inexpliquée.

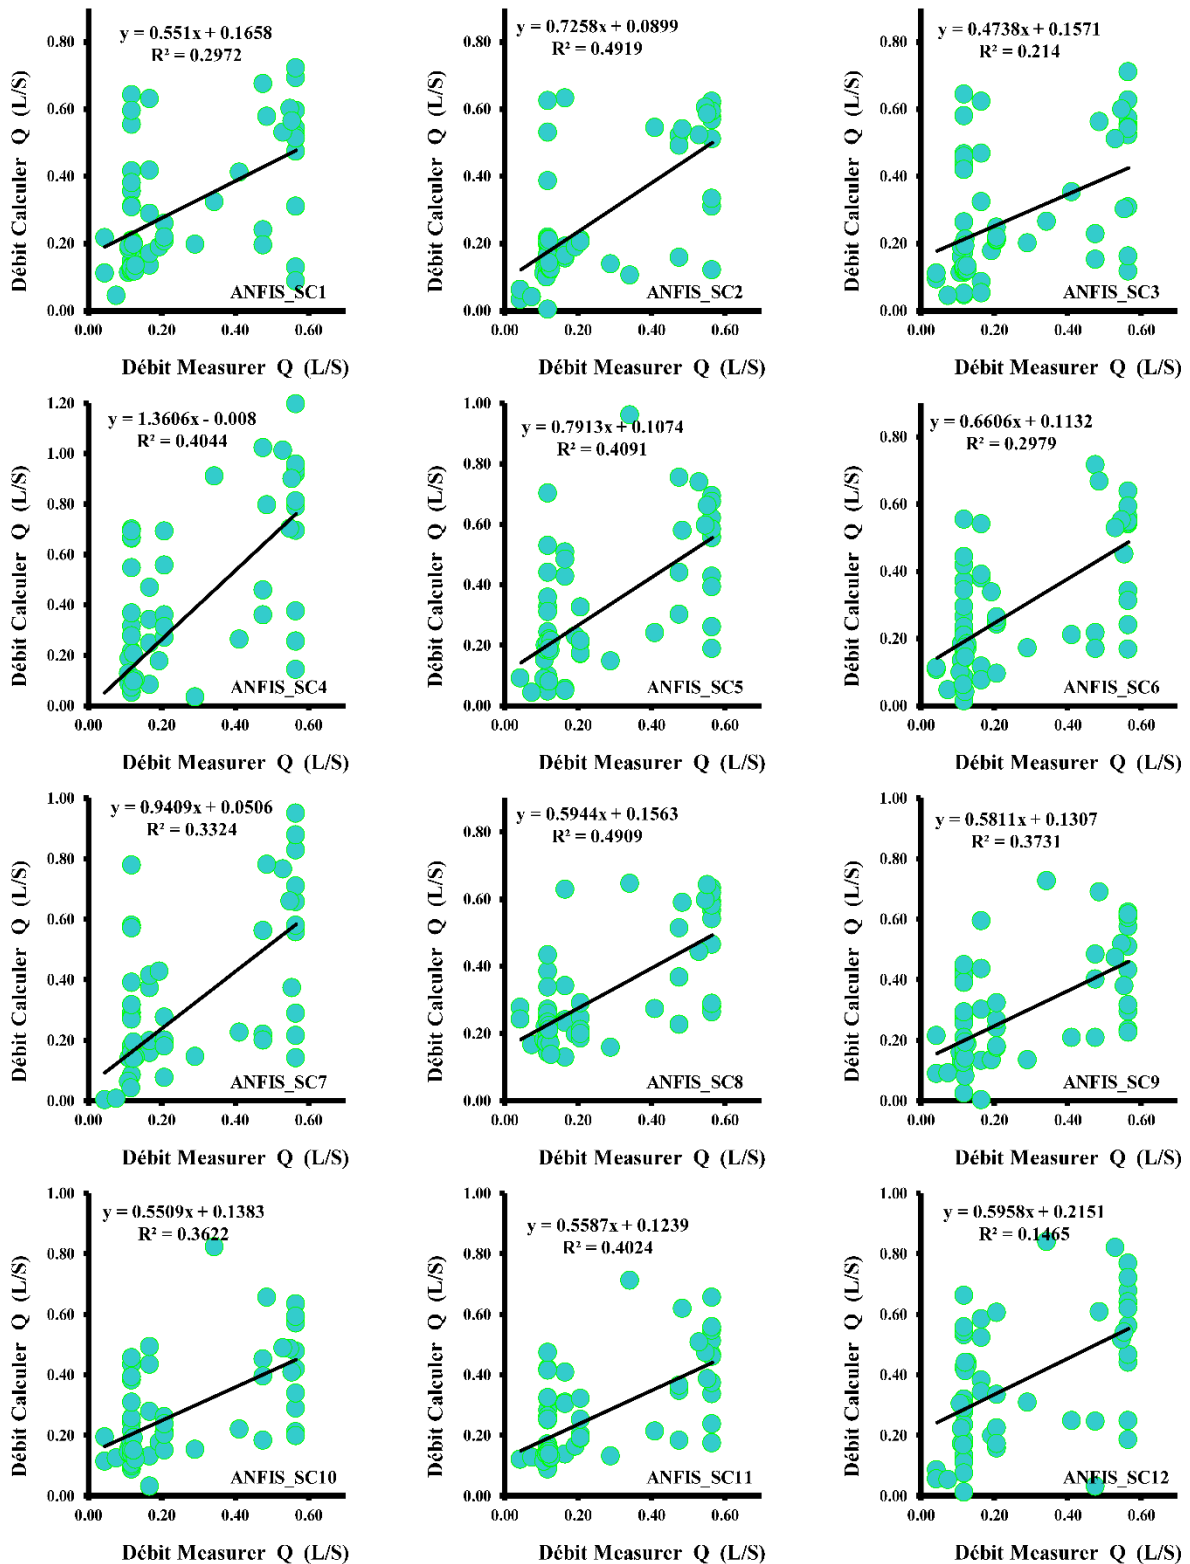


Figure VI. 13. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS\_SC: barrage Foum el Khanga & phase de validation.

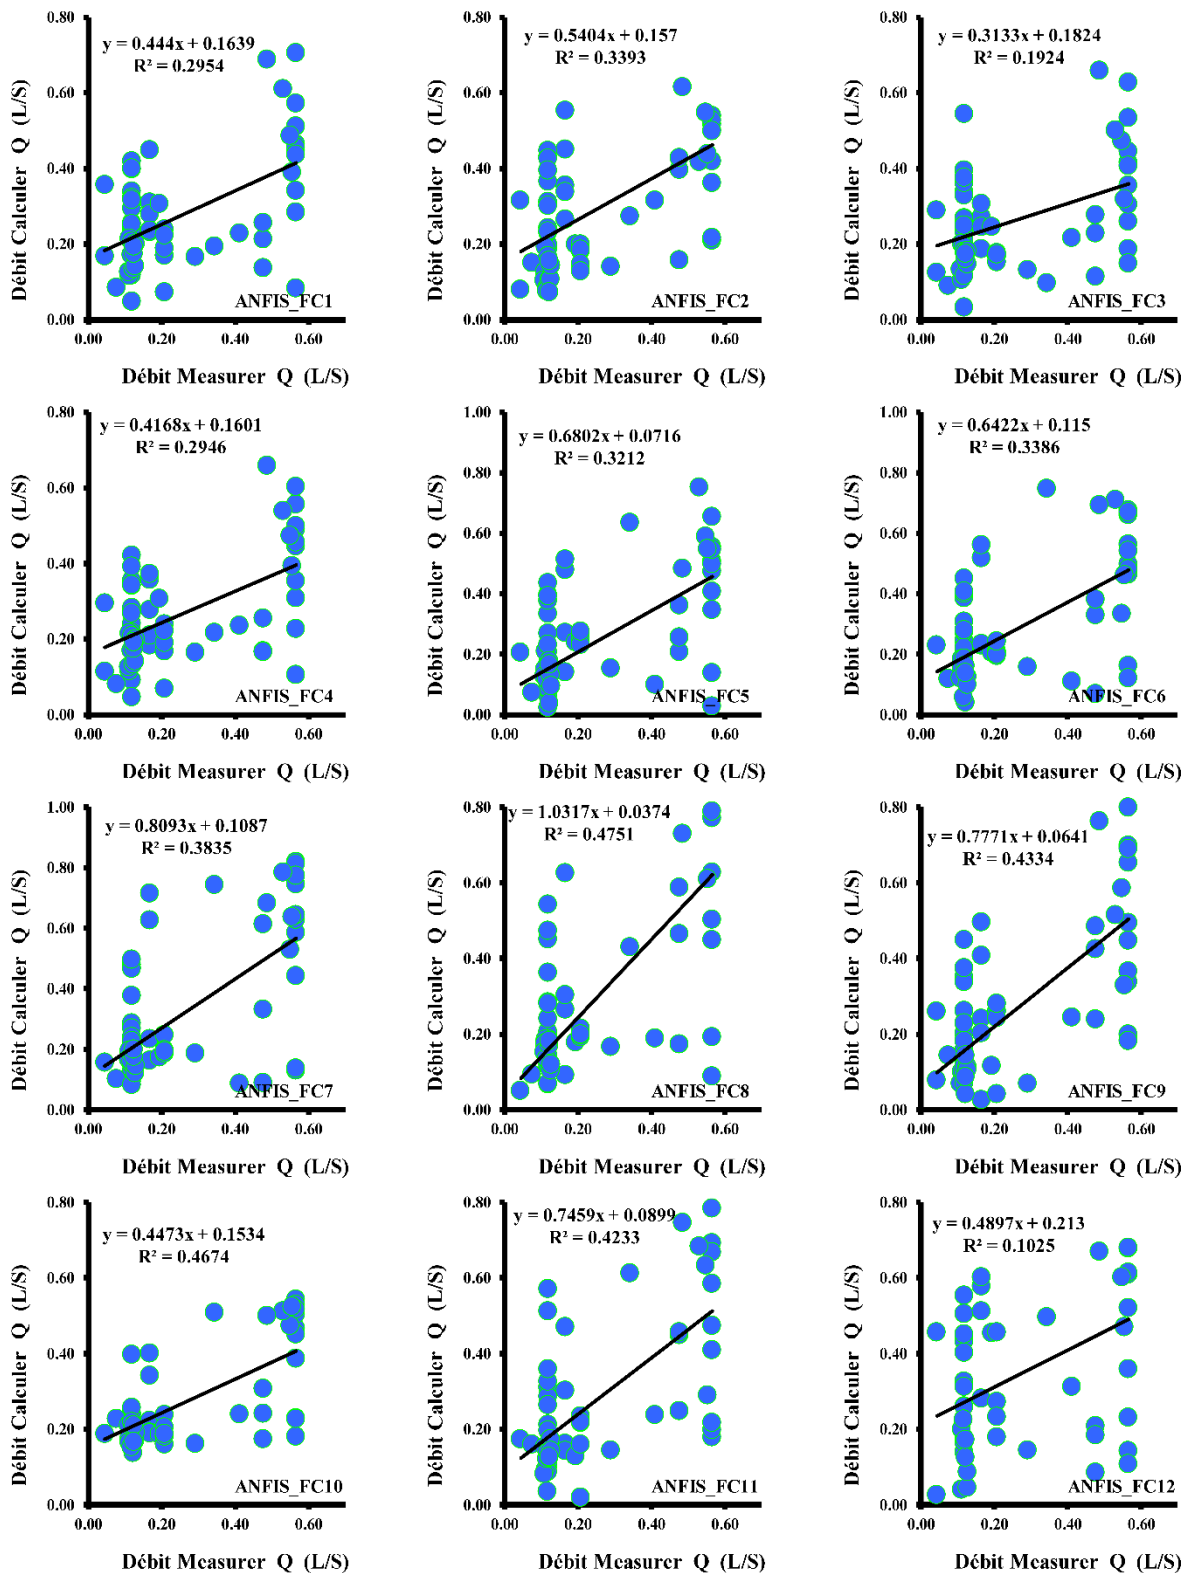


Figure VI. 14. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous ANFIS\_FC: barrage Foum el Khanga & phase de validation.

Les résultats de la phase d'apprentissage suggèrent une corrélation saillante avec la sélection des combinaisons de variables d'entrée. Les modèles intégrant des données piézométriques riches et des entrées temporelles, illustrés par ANFIS\_SC1 à ANFIS\_SC3, ont systématiquement surpassé leurs homologues. À l'inverse, les modèles avec des entrées réduites, en particulier ceux allant d'ANFIS\_SC6 à ANFIS\_SC11, ont montré des erreurs de prédiction perceptibles. Il est à noter que ANFIS\_SC12, malgré une architecture d'entrée plus épurée, a offert des indicateurs de performance comparables aux modèles de niveau supérieur, soulignant l'influence singulière du CPE comme variable pivot. Bien que la phase d'apprentissage fournisse des informations essentielles sur l'efficacité d'un modèle, elle ne couvre qu'une partie des données. Une validation rigoureuse sur de nouveaux ensembles de données est essentielle pour déterminer l'applicabilité globale et la robustesse de chaque modèle dans des scénarios pratiques.

Lors de l'examen de la phase de validation, les performances des modèles divergent de manière significative. En particulier, le modèle ANFIS\_SC2 se distingue en affichant une corrélation élevée, avec un coefficient R de 0.701, et un NSE appréciable de 0.371. Toutefois, il est important de noter que les performances des modèles ANFIS\_SC1 et ANFIS\_SC3 ont connu une baisse substantielle par rapport à leur phase d'apprentissage, avec des valeurs de NSE respectivement de (0.012) et (-0.114). Une telle dégradation dans les performances renforce l'argument précédemment avancé concernant le risque de surajustement de ces modèles. D'autres modèles, notamment ANFIS\_SC4, ANFIS\_SC12, et ANFIS\_SC7, ont rencontré des difficultés lors de cette phase, avec des valeurs de NSE négatives, la plus basse étant de (-2.065) pour ANFIS\_SC4. Le modèle ANFIS\_SC11 mérite une attention particulière en raison de son équilibre entre un coefficient R de 0.634 et un NSE de 0.339. Bien qu'il ne soit pas nécessairement le modèle le plus performant selon une métrique spécifique, sa constance globale suggère qu'il pourrait être un choix préférable pour modéliser l'écoulement par suintement à travers le barrage. Selon l'analyse du Tableau VI.4, il apparaît clairement que l'incorporation de diverses données d'entrée influence considérablement la performance du modèle. Les modèles qui incluent l'ensemble des données piézométriques (PZ1-PZ9), en combinaison avec le calendrier grégorien (YY, MM, DD) et le CPE, manifestent une tendance au surajustement lors de la phase d'apprentissage, comme observé avec ANFIS\_SC1, ANFIS\_SC2, et ANFIS\_SC3. En revanche, l'exclusion de certaines données piézométriques, comme le montrent les modèles ANFIS\_SC4 à ANFIS\_SC6, semble atténuer ce phénomène, conduisant à une meilleure performance en validation. D'autre part, des modèles à entrées réduites, tels que ANFIS\_SC10, ANFIS\_SC11, et ANFIS\_SC12, qui privilégient le calendrier grégorien et moins de points de données piézométriques, montrent une performance constante à travers les phases d'apprentissage et de validation. Il est également important de noter que la réduction systématique des points de données piézométriques, observée d'ANFIS\_SC7 à ANFIS\_SC12, semble induire une amélioration décroissante de la performance du modèle. Cela signale qu'un équilibre optimal entre la complexité des entrées et la performance du modèle doit être recherché. En conclusion, bien que certains modèles affichent des performances d'apprentissage exceptionnelles, leur évaluation en phase de validation est primordiale pour juger de leur capacité de généralisation. ANFIS\_SC11 se présente comme un modèle potentiellement robuste compte tenu de sa performance équilibrée. Toutefois, il convient de

souligner l'importance de contextualiser la sélection du modèle en fonction des besoins et des contraintes spécifiques de l'application en question.

Lors de la phase d'apprentissage, ANFIS\_FC1 a démontré une corrélation linéaire avec une valeur R de 0.706. Cependant, sa valeur NSE de 0.499 indique qu'il a considéré un peu moins de la moitié de la variance des données. Ses valeurs RMSE et MAE de 0.121 et 0.086, respectivement, reflètent des écarts modérés par rapport aux données réelles. ANFIS\_FC2 a présenté des améliorations marginales, avec une valeur R de 0.747 et une NSE de 0.558. Les valeurs RMSE et MAE, respectivement de 0.113 et 0.078, soulignent une meilleure précision par rapport à ANFIS\_FC1. En revanche, ANFIS\_FC3 s'est avéré moins efficace, avec un R de 0.663, un NSE de 0.440, un RMSE de 0.127 et un MAE de 0.091. ANFIS\_FC4 a enregistré un R de 0.701, un NSE de 0.491, un RMSE de 0.121 et un MAE de 0.087, dénotant une légère amélioration par rapport à ANFIS\_FC3. ANFIS\_FC5 s'est distingué avec une R impressionnante de 0.809, un NSE de 0.654, ainsi que des valeurs RMSE et MAE de 0.100 et 0.070 respectivement. ANFIS\_FC6 a produit une R de 0.778, un NSE de 0.605, un RMSE de 0.107 et un MAE de 0.077, tandis qu'ANFIS\_FC7, légèrement supérieur, a enregistré une R de 0.819, un NSE de 0.670, un RMSE de 0.098 et un MAE de 0.062. ANFIS\_FC8 s'est révélé exceptionnel avec une R de 0.898, un NSE de 0.807 et des valeurs minimales de RMSE et MAE égales à 0.075 et 0.046, respectivement. ANFIS\_FC9 a dévoilé une R de 0.838, un NSE de 0.703, un RMSE de 0.093 et un MAE de 0.069. ANFIS\_FC10 a affiché des résultats robustes avec une R de 0.849, un NSE de 0.720, un RMSE de 0.090 et un MAE de 0.059. ANFIS\_FC11 et ANFIS\_FC12 ont montré des performances acceptables, le premier avec une R de 0.820, un NSE de 0.672, un RMSE de 0.097 et un MAE de 0.070, et le second avec une R de 0.873, un NSE de 0.763, un RMSE de 0.083 et un MAE de 0.053. Les disparités de performance entre ces modèles sont principalement attribuables à leurs configurations d'entrée distinctes, mettant en lumière la sensibilité des prédictions selon les paramètres. Certains modèles, comme ANFIS\_FC8, ont bénéficié de combinaisons d'entrées optimales. En conclusion, il est essentiel de trouver un compromis entre complexité et précision pour développer des modèles performants à la fois en phase d'apprentissage et dans des scénarios réels.

Une analyse détaillée des performances des modèles lors de la phase de validation révèle les résultats suivants. Le modèle ANFIS\_FC1 affiche une valeur de R de 0.543, indiquant une corrélation très faible entre les prédictions et les données réelles. Son NSE de 0.210 suggère qu'il capture seulement un cinquième de la variance des données. Les valeurs de RMSE et de MAE, respectivement de 0.167 et 0.134, reflètent des écarts modérés par rapport aux données réelles. ANFIS\_FC2 montre une amélioration par rapport à ANFIS\_FC1, avec un R de 0,582. Cependant, son NSE de 0,180, bien que supérieur à celui d'ANFIS\_FC1, révèle toujours une capture limitée de la variance des données. Les RMSE et MAE, à 0.170 et 0.126, respectivement, indiquent des incohérences. En revanche, ANFIS\_FC3 affiche une diminution des performances, avec un R de 0.439, un NSE faible à 0.116, ainsi que ses valeurs de RMSE et de MAE, de 0.176 et 0,140, témoignent d'une performance faible. ANFIS\_FC4 présente des similitudes avec ANFIS\_FC1 avec un R de 0.543, mais son NSE de 0.242 indique une meilleure capture de la variance. Les valeurs de RMSE et de MAE, de 0.163 et 0.129, sont également légèrement meilleures. Le modèle ANFIS\_FC5 se démarque avec un R de 0.567, mais son NSE


négatif de (-0.084) suggère des prédictions éloignées de la moyenne observée, corroboré par des valeurs de RMSE et de MAE de 0.195 et 0.140.

ANFIS\_FC6, affichant un R de 0.582, présente un NSE de 0.053, indiquant une capture très limitée de la variance. Les valeurs des RMSE et de MAE sont de 0.183 et 0.137. Malgré une valeur R prometteuse de 0.619, ANFIS\_FC7 présente un NSE négatif de -0.189, ce qui est préoccupant. Des valeurs de RMSE et de MAE, à 0.204 et 0.149, mettent en lumière des incohérences. ANFIS\_FC8, malgré un R de 0.689, est contrecarré par un NSE négatif de -0.236. Les valeurs de RMSE et de MAE sont respectivement de 0.208 et 0.145. ANFIS\_FC9 affiche un R de 0.658 et un NSE de 0.160. Les valeurs de RMSE et de MAE sont de 0.172 et 0.130. Se distinguant, le modèle ANFIS\_FC10 présente une valeur R de 0.694 et un NSE de 0.262, l'un des plus élevés. ANFIS\_FC11 offre une valeur R de 0.651, avec un NSE similaire à ANFIS\_FC9 à 0.161. Les valeurs de RMSE et de MAE sont de 0.172 et 0.125. Les résultats sont contrastés pour ANFIS\_FC12 avec une valeur R faible de 0.320, son NSE extrêmement négatif de -1.543 est notable. Au cours de la phase de validation, des modèles tels qu'ANFIS\_FC10, qui équilibrent à la fois les données temporelles et les points de données piézométriques sélectionnés, semblent mieux généraliser. Ceci suggère que bien que des données piézométriques détaillées puissent être bénéfiques lors de l'apprentissage, certaines d'entre elles pourraient être redondantes ou contre-productives lors de l'application des modèles à des données inédites. En conclusion, bien que la complexité des données d'entrée puisse améliorer la performance en phase d'apprentissage d'un modèle, une approche équilibrée et sélective semble plus adaptée aux applications concrètes. Les recherches futures pourraient se concentrer sur l'affinement des combinaisons de données d'entrée, voire envisager l'inclusion de données actuellement non utilisées, afin d'améliorer l'efficacité globale des modèles.


Les résultats obtenus grâce à l'application de divers modèles du système Neuroflous sur le barrage Foum el Khanga permettent de dégager les conclusions suivantes:

- 1) Durant les phases d'apprentissage et de validation, le modèle ANFIS\_SC, plus particulièrement ANFIS\_SC2, a constamment surpassé les modèles ANFIS\_FC, en affichant des R et des NSE élevés. Ces indicateurs reflètent une corrélation linéaire notable entre les valeurs observées et prédites, démontrant la supériorité d'ANFIS\_SC2 en matière de prédiction. Il est important de noter que les faibles valeurs de RMSE et de MAE d'ANFIS\_SC2 mettent en évidence sa précision exceptionnelle.
- 2) Lorsqu'on analyse l'impact des paramètres temporels, des modèles tels que M2, qui excluent les informations du calendrier Grégorien tout en conservant les autres variables, affichent généralement de meilleures performances. Cette tendance est particulièrement évidente dans le cas des variantes ANFIS\_SC. Par exemple, la comparaison entre ANFIS\_SC1 (intégrant la date) et ANFIS\_SC2 (excluant la date) révèle une augmentation des valeurs de R et NSE lors de la validation, passant de 0.545 à 0.701 et de 0.012 à 0.371, respectivement. Cette différence suggère que les paramètres de la date grégorienne pourraient jouer un rôle secondaire par rapport aux données piézométriques dans la prédiction du débit des fuites.

- 3) Le niveau d'eau dans le réservoir, représenté par l'acronyme CPE, s'avère être un paramètre crucial. Des modèles tels que M1, qui intègrent le CPE, surpassent largement leurs homologues tels que M3, qui ne tiennent pas compte du CPE, même s'ils partagent les mêmes données piézométriques.
- 4) La simplicité peut souvent rivaliser avec la complexité. Par exemple, le modèle M11, qui n'utilise que des données temporelles, une seule mesure piézométrique et le CPE, atteint des performances comparables à certains des modèles les plus complexes. Cela souligne l'idée que des modèles avec moins d'entrées, mais cruciales, peuvent toujours fournir des prédictions robustes, minimisant ainsi le risque de surajustement.
- 5) L'exclusion séquentielle des points de données piézométriques des modèles, comme illustré de M1 à M12 dans le cadre ANFIS\_FC, ne conduit pas à une diminution proportionnelle des résultats de validation. Cette observation suggère que l'importance des points de données piézométriques individuels peut varier.
- 6) Finalement, nous comparons entre les différents modèles en utilisant les boxplot, violon plot et le diagramme de Taylor, comme représentés sur les deux figures



**Figure VI. 15.** Comparaison entre les différents ANN modèles par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Foum el Khanga.



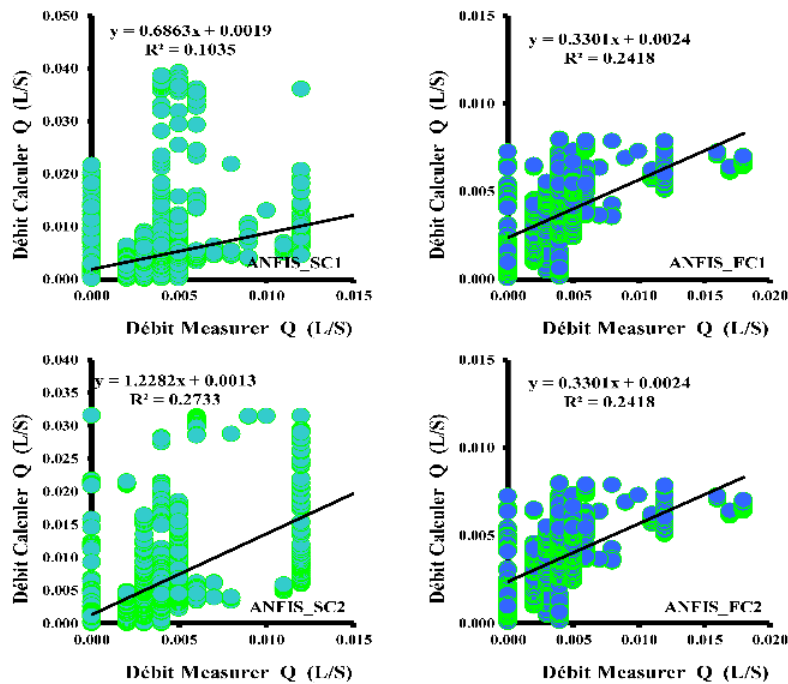
**Figure VI. 16.** Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles: Barrage Foum el Khanga.

## VI.7. Résultats Obtenus par les modèles Neuroflous: Barrage Hammam Debagh

Lors de la phase d'apprentissage, le modèle ANFIS\_SC1 incluant la date du calendrier grégorien, le niveau d'eau du réservoir (CPE) et le volume d'eau du réservoir (VOL) comme paramètres, a démontré une performance notable. Ce modèle a enregistré un R de 0.902, témoignant d'une forte relation linéaire positive avec les observations. Par ailleurs, son NSE s'établissait à 0.814, signalant une concordance appréciable avec les données de référence. Les indices d'erreur RMSE et MAE ont tous deux été mesurés à 0.001, indiquant de faibles écarts par rapport aux observations. À titre comparatif, ANFIS\_SC2, n'incorporant que le CPE et le VOL, a montré une performance légèrement inférieure. Sa valeur R s'établissait à 0.791 et son NSE à 0.626. De plus, les valeurs de RMSE et MAE pour ce modèle étaient respectivement de 0.002 et 0.001. Cependant, en phase de validation, une baisse de performance du modèle ANFIS\_SC1 a été remarquée, avec une valeur R de 0.322. De manière alarmante, son NSE est devenu négatif, atteignant -3,233. Les indices d'erreur ont également augmenté, avec un RMSE à 0.006 et un MAE à 0.002. En revanche, le modèle ANFIS\_SC2 a enregistré une valeur R de 0.523 et un NSE de -3.565, avec des erreurs RMSE et MAE respectivement de 0.006 et 0.004.

**Tableau VI. 5.** Performances des différents modèles Neuroflous & barrage Hammam Debagh.

| Models    | Training |       |       |       | Validation |        |       |       |
|-----------|----------|-------|-------|-------|------------|--------|-------|-------|
|           | R        | NSE   | RMSE  | MAE   | R          | NSE    | RMSE  | MAE   |
| ANFIS_SC1 | 0.902    | 0.814 | 0.001 | 0.001 | 0.322      | -3.233 | 0.006 | 0.002 |
| ANFIS_SC2 | 0.791    | 0.626 | 0.002 | 0.001 | 0.523      | -3.565 | 0.006 | 0.004 |
| ANFIS_FC1 | 0.936    | 0.821 | 0.678 | 0.671 | 0.932      | 0.988  | 0.158 | 0.090 |
| ANFIS_FC2 | 0.563    | 0.318 | 0.002 | 0.001 | 0.492      | 0.208  | 0.003 | 0.002 |



**Figure VI. 17.** Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Neuroflous: barrage Hammam Debagh & phase de validation.

L'analyse suggère qu'en phase d'apprentissage, l'intégration des dates du calendrier grégorien a conféré un avantage à ANFIS\_SC 1. Néanmoins, en phase de validation, les deux modèles ont manifesté des signes de surajustement. ANFIS\_SC 2, malgré ses entrées simplifiées, a affiché une constance relative dans ses performances entre les deux phases. En conclusion, bien que ANFIS\_SC1 ait montré une performance supérieure lors de l'apprentissage, sa performance s'est dégradée en validation. ANFIS\_SC 2, malgré des entrées simplifiées, a démontré une stabilité relative. Ces résultats indiquent que les variables du calendrier grégorien pourraient avoir un impact significatif sur la performance du modèle.

Au cours de la phase d'apprentissage, le modèle ANFIS\_FC1 qui a intégré des données du calendrier grégorien (AA, MM, JJ) en combinaison avec le niveau d'eau (CPE) et le volume d'eau (VOL) a révélé une performance remarquable. Ce modèle a enregistré une valeur de R à 0.936, reflétant une corrélation robuste entre ses prédictions et les observations. Par ailleurs, son NSE s'est élevé à 0.821, témoignant de sa précision comparée à la moyenne des données observées. Toutefois, une attention particulière doit être portée aux valeurs de RMSE et MAE pour ANFIS\_FC1, qui sont respectivement de 0.678 et 0.671, indiquant des écarts notables entre les prédictions et les valeurs réelles. En parallèle, ANFIS\_FC2, se basant uniquement sur le niveau d'eau (CPE) et le volume d'eau (VOL), a affiché des performances moindres. Avec un R de 0.563 et un NSE de 0.318, ses prédictions n'étaient pas aussi alignées sur les observations que celles de ANFIS\_FC1. Néanmoins, ANFIS\_FC2 se distingue par des valeurs RMSE et MAE plus faibles, à 0.002 et 0.001 respectivement, montrant une proximité générale avec les observations. En transition vers la phase de validation, ANFIS\_FC1 conserve son excellence, affichant un R de 0.932 et un impressionnant NSE de 0.988. Les erreurs, représentées par RMSE et MAE, sont désormais respectivement de 0.158 et 0.090, montrant une amélioration notable. En revanche, ANFIS\_FC2 présente des résultats plus modestes avec un R de 0.492 et un NSE de 0.208, malgré des valeurs de RMSE et MAE stables et faibles à 0.003 et 0.002. En synthèse, ANFIS\_FC1, enrichi par des données temporelles, a systématiquement démontré une supériorité sur ANFIS\_FC2. Ces données temporelles semblent apporter un contexte crucial, suggérant une influence des tendances et motifs temporels sur le débit d'infiltration. Il est toutefois prudent de souligner les écarts notables de ANFIS\_FC1 durant la phase d'apprentissage. En opposition, ANFIS\_FC2, malgré son ensemble de données simplifié, a démontré une régularité, mais avec une capture moins adéquate des données. En définitive, ANFIS\_FC1 apparaît comme le modèle privilégié pour la modélisation du débit d'infiltration, mettant en exergue l'importance des données temporelles dans les modélisations hydrologiques.

Les résultats obtenus par divers modèles de système Neuroflous pour le barrage Hammam Debagh permettent de tirer les conclusions suivantes:

1. Les modèles formulés en utilisant les paramètres d'entrée encapsulés par le Modèle M1, en particulier les données du calendrier grégorien (YY, MM, DD) associées au niveau d'eau du réservoir (CPE) et au volume (VOL), présentent une amélioration notable de leurs capacités prédictives par rapport à un modèle qui ne tient pas compte des données du calendrier grégorien dans l'approche ANFIS\_FC. Cependant, dans l'approche

- ANFIS\_SC, l'inverse se produit, et on observe une dégradation significative des performances en passant de la phase d'apprentissage à la phase de validation.
2. Il convient de souligner en particulier que l'efficacité du modèle ANIFS\_FC1 est prononcée lors de la phase d'apprentissage, atteignant un coefficient de corrélation supérieur à 0.936. Il démontre une stabilité remarquable des performances et une excellente capacité de généralisation lors de la phase de validation, où il atteint un coefficient de corrélation supérieur à 0.932.
  3. En comparaison, les modèles élaborés à l'aide des paramètres définis par le Modèle 2 (CPE, VOL) ont montré des performances relativement modestes. Cependant, parmi ces modèles, ANFIS\_SC2 se démarque en obtenant des performances supérieures à celles du modèle ANFIS\_SC1, avec un coefficient de corrélation R de 0.523 lors de la phase de validation.
  4. Une conclusion essentielle de cette analyse met en évidence l'influence significative des variables du calendrier grégorien (YY, MM, DD). L'intégration de ces paramètres temporels est cruciale pour améliorer la précision des prévisions relatives au débit de fuite à travers le barrage dans l'approche ANFIS\_FC.

## VI.8. Conclusion

Ce chapitre présente une analyse approfondie de l'application des méthodes du système ANFIS dans la modélisation de l'infiltration et des pertes d'eau à travers plusieurs barrages situés dans le nord de l'Algérie. Les barrages sélectionnés, notamment Bougouss, Chaurfas Mascara, Zit Emba, et Hammam Debagh, sont d'une importance cruciale pour la gestion de la ressource hydrique. Ils ont été choisis comme échantillons en raison de leur répartition géographique sur l'ensemble du territoire nord-algérien, offrant ainsi une perspective plus globale sur le phénomène d'infiltration à travers les barrages dans cette région. La mise en œuvre de ces méthodes d'IA a permis de tirer plusieurs conclusions significatives. Tout d'abord, l'efficacité des modèles ANFIS peut varier en fonction du barrage étudié. Par exemple, les modèles ANFIS\_SC se sont avérés performants pour le barrage Bougouss, tandis qu'ANFIS\_FC a affiché des performances supérieures pour le barrage Bouhamdane. Cette variabilité souligne l'importance de choisir la méthode la mieux adaptée à chaque situation. Un point clé réside dans la sélection judicieuse des variables d'entrée. Il est évident que la quantité d'entrées n'est pas nécessairement proportionnelle à la qualité des prédictions. Il est primordial de choisir des variables pertinentes et d'éviter une augmentation indiscriminée du nombre d'entrées, ce qui peut conduire à des modèles sur ajustés. L'inclusion ou l'exclusion de données liées au calendrier grégorien a été identifiée comme un facteur critique, avec des impacts variables sur la performance des modèles. De même, le niveau d'eau du réservoir (CPE) s'est révélé être un paramètre essentiel pour améliorer la précision des prévisions, suggérant que la surveillance de ce paramètre est cruciale dans la gestion des barrages. En outre, l'emplacement et la pertinence des points piézométriques ont montré une influence significative sur les performances des modèles, avec certains points étant plus informatifs que d'autres. En général, la simplicité des modèles, avec moins d'entrées cruciales, peut rivaliser avec la complexité, à condition que ces entrées soient judicieusement choisies. Enfin, il est impératif de souligner que les performances des modèles ANFIS peuvent varier d'un barrage à l'autre en fonction des caractéristiques

hydrologiques et géologiques spécifiques de chaque site. Par conséquent, des approches personnalisées doivent être envisagées pour chaque barrage, avec une attention particulière portée aux caractéristiques uniques des données et des variables d'entrée. Dans l'ensemble, les résultats de cette étude illustrent le potentiel prometteur des méthodologies de système Neuroflous pour la modélisation de l'infiltration et de la fuite à travers les barrages en remblai. Ils offrent un cadre d'analyse utile pour améliorer la gestion de ces infrastructures cruciales et contribuer ainsi à la sécurité et à l'efficacité de l'approvisionnement en eau, tout en posant les bases d'une recherche future dans le domaine de l'hydrologie.

---

**Chapitre VII : Modélisation des Débits de Fuite par  
Les Modèles Ensemblistes**

---

## VII.1. Introduction

La modélisation des flux d'infiltration complexe à l'intérieur des barrages en remblai constitue un défi continu qui nécessite l'application de techniques de modélisation innovantes et précises. Le processus d'infiltration à travers les barrages en remblai est un phénomène multifacette influencé par des facteurs géologiques et hydrauliques complexes. Les méthodes analytiques conventionnelles se révèlent souvent insuffisantes pour appréhender les subtilités de ces phénomènes. Dans le présent chapitre (N°7), nous entreprenons un examen approfondi en explorant les nuances de la modélisation et une évaluation approfondie de divers modèles, notamment le LSSVM, le MARS et le M5TREE, ainsi que de leurs performances au cours des phases d'apprentissage et de validation. Les conclusions tirées de chaque barrage, à savoir Bougous, le Barrage Chaurfas Mascara, le Barrage Zit Emba, le Barrage Foum El Khanga et Hammam Debagh, mettent en évidence l'importance cruciale du choix judicieux des données d'entrée et de l'équilibre entre la complexité du modèle et sa capacité de généralisation. En évaluant l'efficacité du LSSVM, du MARS et du M5Tree dans le contexte de la modélisation des flux d'infiltration, notre objectif est de fournir aux ingénieurs et aux chercheurs des outils avancés pour la conception, le suivi et la maintenance des barrages en remblai. Les connaissances acquises grâce à cette exploration contribueront de manière significative au domaine de l'hydrologie et de l'ingénierie des barrages, influençant ainsi la future modélisation des flux d'infiltration et la résilience de notre infrastructure. En examinant les caractéristiques spécifiques et les performances de chaque modèle, notre objectif est de formuler des conclusions solides et des recommandations, en mettant en lumière l'importance critique de certaines données et de la structure du modèle. En parcourant ce chapitre, vous développerez une compréhension approfondie de l'importance des données piézométriques, des avantages potentiels des variables temporelles et des défis liés au surajustement. Ce chapitre offre une perspective complète sur les efforts actuels en matière de modélisation hydrologique.

## VII.2. Mise En Œuvre Des Modèles Ensembliste Sous Matlab

La mise en œuvre du modèle LSSVM sous MatLab nécessite plusieurs étapes, notamment la récupération des données à partir de jeux de données Excel, la division de ces données en sous-ensembles d'apprentissage et de validation. Pour le modèle LSSVM, le type d'approximation de fonction est choisi, et le noyau de Fonction Radiale de Base (RBF) est privilégié en raison de sa capacité à cartographier des relations non linéaires. Bien que les hyperparamètres soient préconfigurés dans le script fourni, il est envisageable d'optimiser ces paramètres lors des itérations futures. Le modèle est initialisé à l'aide de la fonction "*initlssvm*" et est ensuite formé grâce à "*trainlssvm*". Les prédictions sont effectuées à l'aide de "*simlssvm*" et comparées aux valeurs réelles. Les puissantes capacités numériques de MATLAB, combinées à l'efficacité de la modélisation LSSVM, en font un cadre essentiel pour les chercheurs. Les modèles MARS représentent une méthode de régression non linéaire qui permet de discerner des relations complexes en utilisant des fonctions linéaires par morceaux. Dans le domaine de la recherche hydrologique, l'implémentation du modèle MARS à l'aide de la boîte à outils *ARESLab* dans Matlab se révèle essentielle. Avant d'entreprendre la modélisation, il est crucial de normaliser les données, ce qui est accompli grâce à la fonction "*mapstd*" de Matlab. Les paramètres qui influent sur la complexité du modèle, tels que "*maxFuncs*", "*c*", et "*cubic*", sont définis avant de créer le modèle. La construction du modèle s'effectue à l'aide de la fonction

"*aresbuild*", et les prédictions sont réalisées à l'aide de "*arespredict*". Pour rendre les résultats prédits contextuellement pertinents, il est nécessaire de *dénormliser* ces résultats par la suite.

Le modèle d'Arbre M5Tree, combine les avantages des arbres de décision et de la régression linéaire pour modéliser de manière efficace des relations de données complexes et non linéaires. Avec le support de Matlab, la mise en œuvre du modèle d'Arbre M5Tree devient efficiente. Les données sont extraites à partir de fichiers Excel dédiés à l'apprentissage et à la validation. Le modèle d'Arbre M5Tree est paramétré en utilisant la fonction "*m5pparams*", avec des paramètres essentiels tels que "*modelTree*" et "*minNumCases*". Une fois que les paramètres sont configurés, l'apprentissage est exécuté en utilisant la fonction "*m5pbuid*". Les prédictions, après *dénormlisation*, sont enregistrées à nouveau dans Excel pour des évaluations ultérieures. Le modèle d'Arbre M5Tree dans Matlab offre une approche robuste pour la prédiction de relations complexes, grâce à sa capacité à reconnaître des motifs dans des données nuancées.

### VII.3. Résultats Obtenus par les modèles Ensembliste : Barrage Bougous

Le **Tableau VII.1** comporte les résultats de modélisation par les modèles Ensembliste pour le barrage Bougous. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents modèles ensembliste (barrage bougouss) sont reportés dans la **Figure VII.1-3**. En phase d'apprentissage, les résultats ont montré que, le modèle LSSVM12 a démontré une performance exceptionnelle, obtenant une valeur R de 0.999, un NSE de 0.999, un RMSE de 0.515 et un MAE de 0.349 en utilisant uniquement le calendrier grégorien et le niveau du réservoir d'eau (CPE) comme entrées. En revanche, le modèle LSSVM2, qui utilise sept entrées, a affiché un R de 0.984, un NSE de 0.966, un RMSE de 3.029 et un MAE de 2.012, suggérant que l'introduction de davantage de variables peut entraîner du bruit. Les modèles LSSVM3 et LSSVM4 ont présenté des performances similaires, avec des valeurs R autour de 0.998, des NSE proches de 0.995, des RMSE de 1.204 et 1.190, ainsi que des MAE de 0.793 et 0.771, respectivement. Le modèle LSSVM11 a obtenu un R de 0.999, un NSE de 0.997, un RMSE de 0.853 et un MAE de 0.542. Les modèles intermédiaires, LSSVM1 et LSSVM5 à LSSVM10, ont montré des performances variables, avec des valeurs R allant de 0.994 à 0.998, des NSE de 0.987 à 0.996, des RMSE de 0.908 à 1.860 et des MAE de 0.575 à 1.156. En conclusion, l'étude révèle l'importance d'une sélection précise des caractéristiques et d'une compréhension approfondie du système hydrologique dans la performance du modèle.

La validation a une importance cruciale pour évaluer l'adaptabilité et la précision d'un modèle. LSSVM1 a affiché un coefficient R=0.956, un Coefficient NSE =0.911, un RMSE de 4.869 et une MAE de 3.270. Les performances de LSSVM2 se sont traduites par un R de 0.912, un NSE de 0.826, un RMSE de 6.802 et un MAE de 4.858. LSSVM4 a obtenu des métriques de R=0.956, NSE=0.911, RMSE=4.880 et MAE=3.280. Notons que les performances de validation du LSSVM12 ont divergé, affichant un R de 0.926, un NSE de 0.851, un RMSE de 6.307 et un MAE de 4.450. Tant LSSVM8 que LSSVM9 ont présenté des valeurs de R proches de 0.939, des NSE autour de 0.879, des RMSE à environ 5.677 et des MAE d'environ 3.754. Les modèles intermédiaires, LSSVM3 à LSSVM7 et LSSVM10 à LSSVM11, ont montré des valeurs de R allant de 0.911 à 0.948, des NSE entre 0.822 et 0.895, des RMSE de 5.296 à 6.885 et des MAE de 3.547 à 4.705. Les résultats de validation mettent en évidence l'importance de

trouver un équilibre entre l'optimisation du modèle pour des ensembles de données bien connus et la garantie de sa généralisation. La forte performance en phase d'apprentissage du modèle LSSVM12, attribuable à la combinaison des variables temporelles et du niveau du réservoir d'eau (CPE), souligne l'influence des variables d'entrée. Cependant, des modèles tels que LSSVM2 montrent que l'ajout de plus de données n'entraîne pas nécessairement une amélioration des résultats.

**Tableau VII. 1.** Performances des différents modèles Ensemblistes & barrage Bougous.

| Models   | Training |       |       |       | Validation |       |        |       |
|----------|----------|-------|-------|-------|------------|-------|--------|-------|
|          | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE   | MAE   |
| LSSVM1   | 0.998    | 0.996 | 1.055 | 0.685 | 0.956      | 0.911 | 4.869  | 3.270 |
| LSSVM2   | 0.984    | 0.966 | 3.029 | 2.012 | 0.912      | 0.826 | 6.802  | 4.858 |
| LSSVM3   | 0.998    | 0.995 | 1.204 | 0.793 | 0.948      | 0.895 | 5.296  | 3.547 |
| LSSVM4   | 0.998    | 0.995 | 1.190 | 0.771 | 0.956      | 0.911 | 4.880  | 3.280 |
| LSSVM5   | 0.996    | 0.991 | 1.523 | 1.006 | 0.932      | 0.866 | 5.969  | 3.839 |
| LSSVM6   | 0.994    | 0.987 | 1.860 | 1.156 | 0.920      | 0.844 | 6.453  | 4.084 |
| LSSVM7   | 0.994    | 0.988 | 1.822 | 1.149 | 0.934      | 0.868 | 5.924  | 3.925 |
| LSSVM8   | 0.999    | 0.997 | 0.908 | 0.575 | 0.937      | 0.876 | 5.754  | 3.881 |
| LSSVM9   | 0.997    | 0.994 | 1.232 | 0.791 | 0.941      | 0.882 | 5.600  | 3.628 |
| LSSVM10  | 0.995    | 0.990 | 1.666 | 1.089 | 0.911      | 0.822 | 6.885  | 4.705 |
| LSSVM11  | 0.999    | 0.997 | 0.853 | 0.542 | 0.946      | 0.891 | 5.378  | 3.656 |
| LSSVM12  | 0.999    | 0.999 | 0.515 | 0.349 | 0.926      | 0.851 | 6.307  | 4.450 |
| MARS1    | 0.993    | 0.987 | 1.867 | 1.345 | 0.963      | 0.904 | 5.059  | 3.289 |
| MARS2    | 0.914    | 0.835 | 6.646 | 4.795 | 0.755      | 0.538 | 11.093 | 7.940 |
| MARS3    | 0.992    | 0.984 | 2.057 | 1.463 | 0.920      | 0.843 | 6.458  | 4.519 |
| MARS4    | 0.985    | 0.970 | 2.826 | 1.940 | 0.934      | 0.864 | 6.027  | 4.258 |
| MARS5    | 0.985    | 0.970 | 2.826 | 1.940 | 0.934      | 0.864 | 6.027  | 4.258 |
| MARS6    | 0.991    | 0.983 | 2.140 | 1.519 | 0.917      | 0.786 | 7.553  | 5.007 |
| MARS7    | 0.960    | 0.921 | 4.610 | 3.449 | 0.886      | 0.781 | 7.636  | 5.354 |
| MARS8    | 0.988    | 0.976 | 2.521 | 1.849 | 0.947      | 0.868 | 5.925  | 4.258 |
| MARS9    | 0.990    | 0.979 | 2.355 | 1.628 | 0.954      | 0.895 | 5.297  | 3.628 |
| MARS10   | 0.985    | 0.970 | 2.827 | 1.800 | 0.955      | 0.899 | 5.179  | 3.489 |
| MARS11   | 0.946    | 0.894 | 5.327 | 3.562 | 0.886      | 0.783 | 7.607  | 5.561 |
| MARS12   | 0.977    | 0.955 | 3.471 | 2.373 | 0.944      | 0.887 | 5.481  | 3.551 |
| M5Tree1  | 0.973    | 0.943 | 3.923 | 2.427 | 0.958      | 0.893 | 5.325  | 3.608 |
| M5Tree2  | 0.981    | 0.962 | 3.192 | 1.921 | 0.797      | 0.569 | 10.709 | 5.945 |
| M5Tree3  | 0.971    | 0.940 | 3.999 | 2.371 | 0.953      | 0.867 | 5.950  | 3.852 |
| M5Tree4  | 0.973    | 0.943 | 3.923 | 2.427 | 0.958      | 0.893 | 5.325  | 3.608 |
| M5Tree5  | 0.969    | 0.937 | 4.126 | 2.492 | 0.959      | 0.886 | 5.508  | 3.885 |
| M5Tree6  | 0.966    | 0.931 | 4.314 | 2.598 | 0.959      | 0.879 | 5.669  | 3.969 |
| M5Tree7  | 0.968    | 0.931 | 4.294 | 2.671 | 0.951      | 0.851 | 6.298  | 4.113 |
| M5Tree8  | 0.969    | 0.934 | 4.209 | 2.608 | 0.951      | 0.852 | 6.279  | 4.082 |
| M5Tree9  | 0.952    | 0.896 | 5.290 | 3.393 | 0.916      | 0.837 | 6.596  | 4.259 |
| M5Tree10 | 0.945    | 0.887 | 5.515 | 3.630 | 0.935      | 0.870 | 5.878  | 4.143 |
| M5Tree11 | 0.950    | 0.889 | 5.453 | 3.674 | 0.921      | 0.848 | 6.368  | 4.406 |
| M5Tree12 | 0.948    | 0.886 | 5.528 | 3.603 | 0.916      | 0.836 | 6.606  | 4.325 |

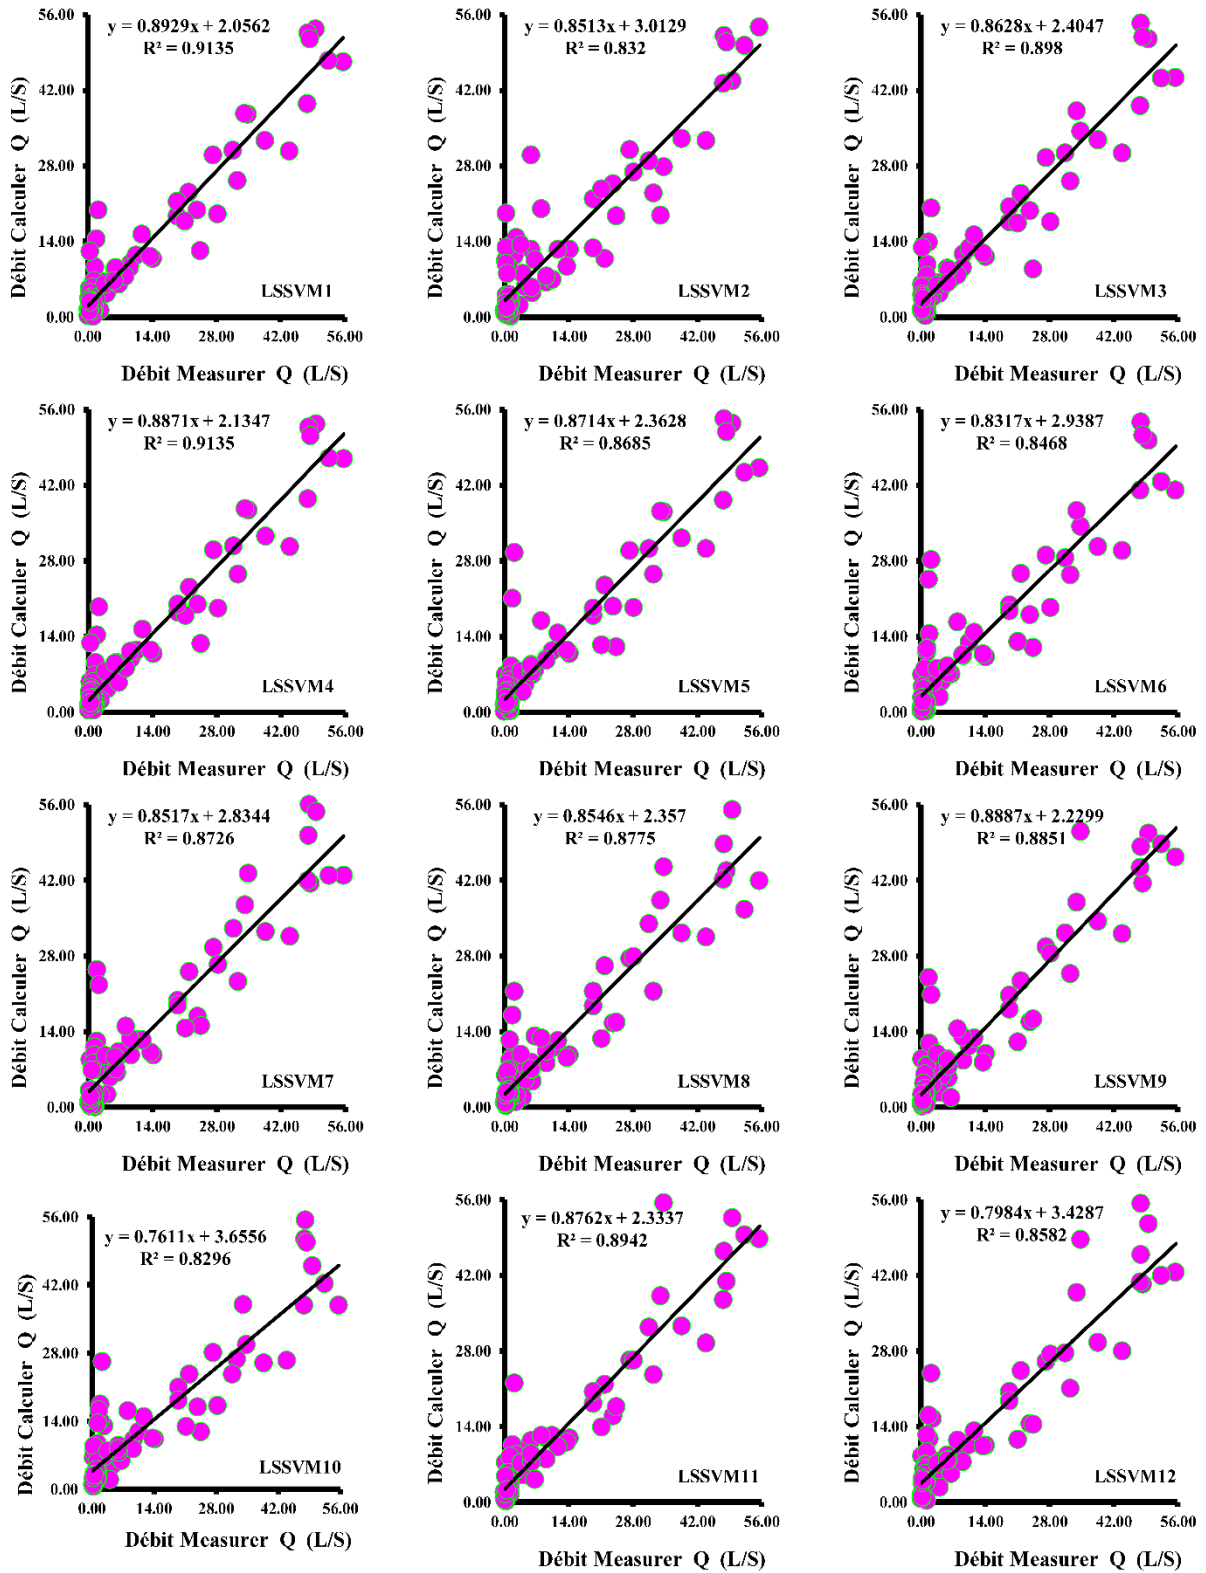


Figure VII. 1. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles LSSVM: barrage Bougous & phase de validation.

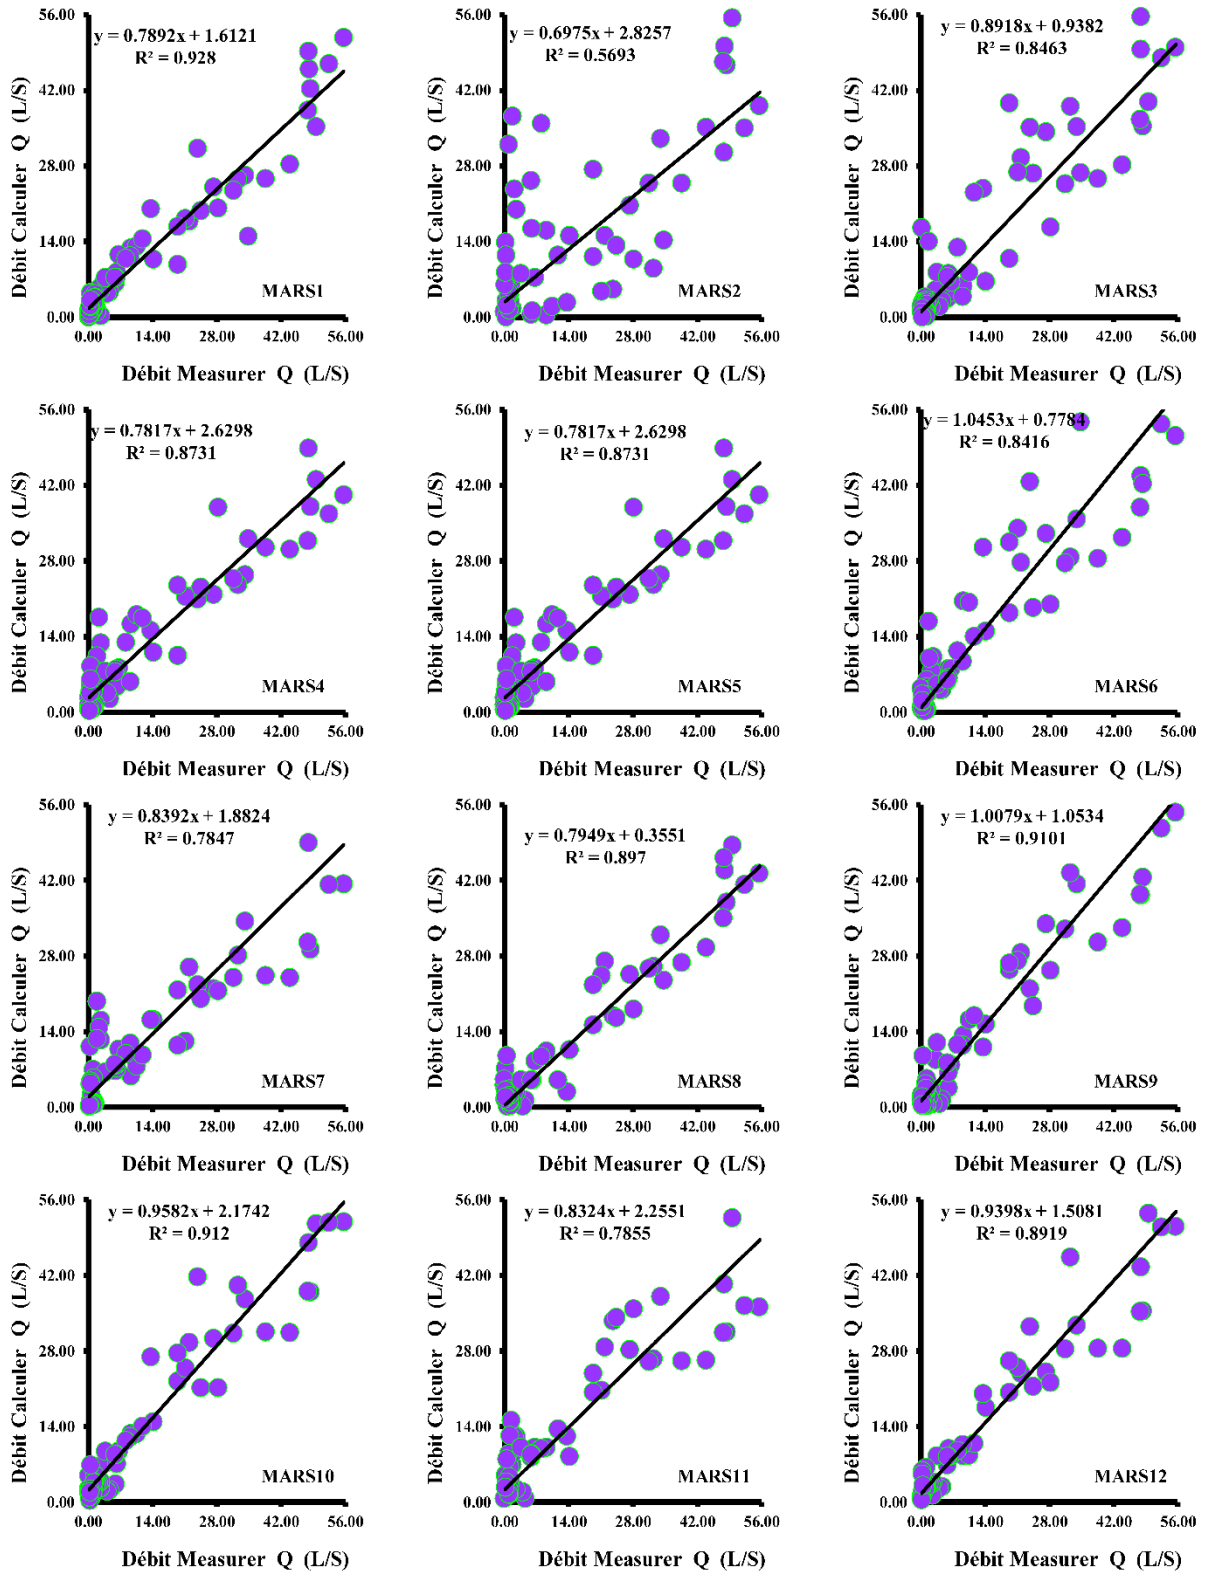


Figure VII. 2. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles MARS: barrage Bougous & phase de validation.

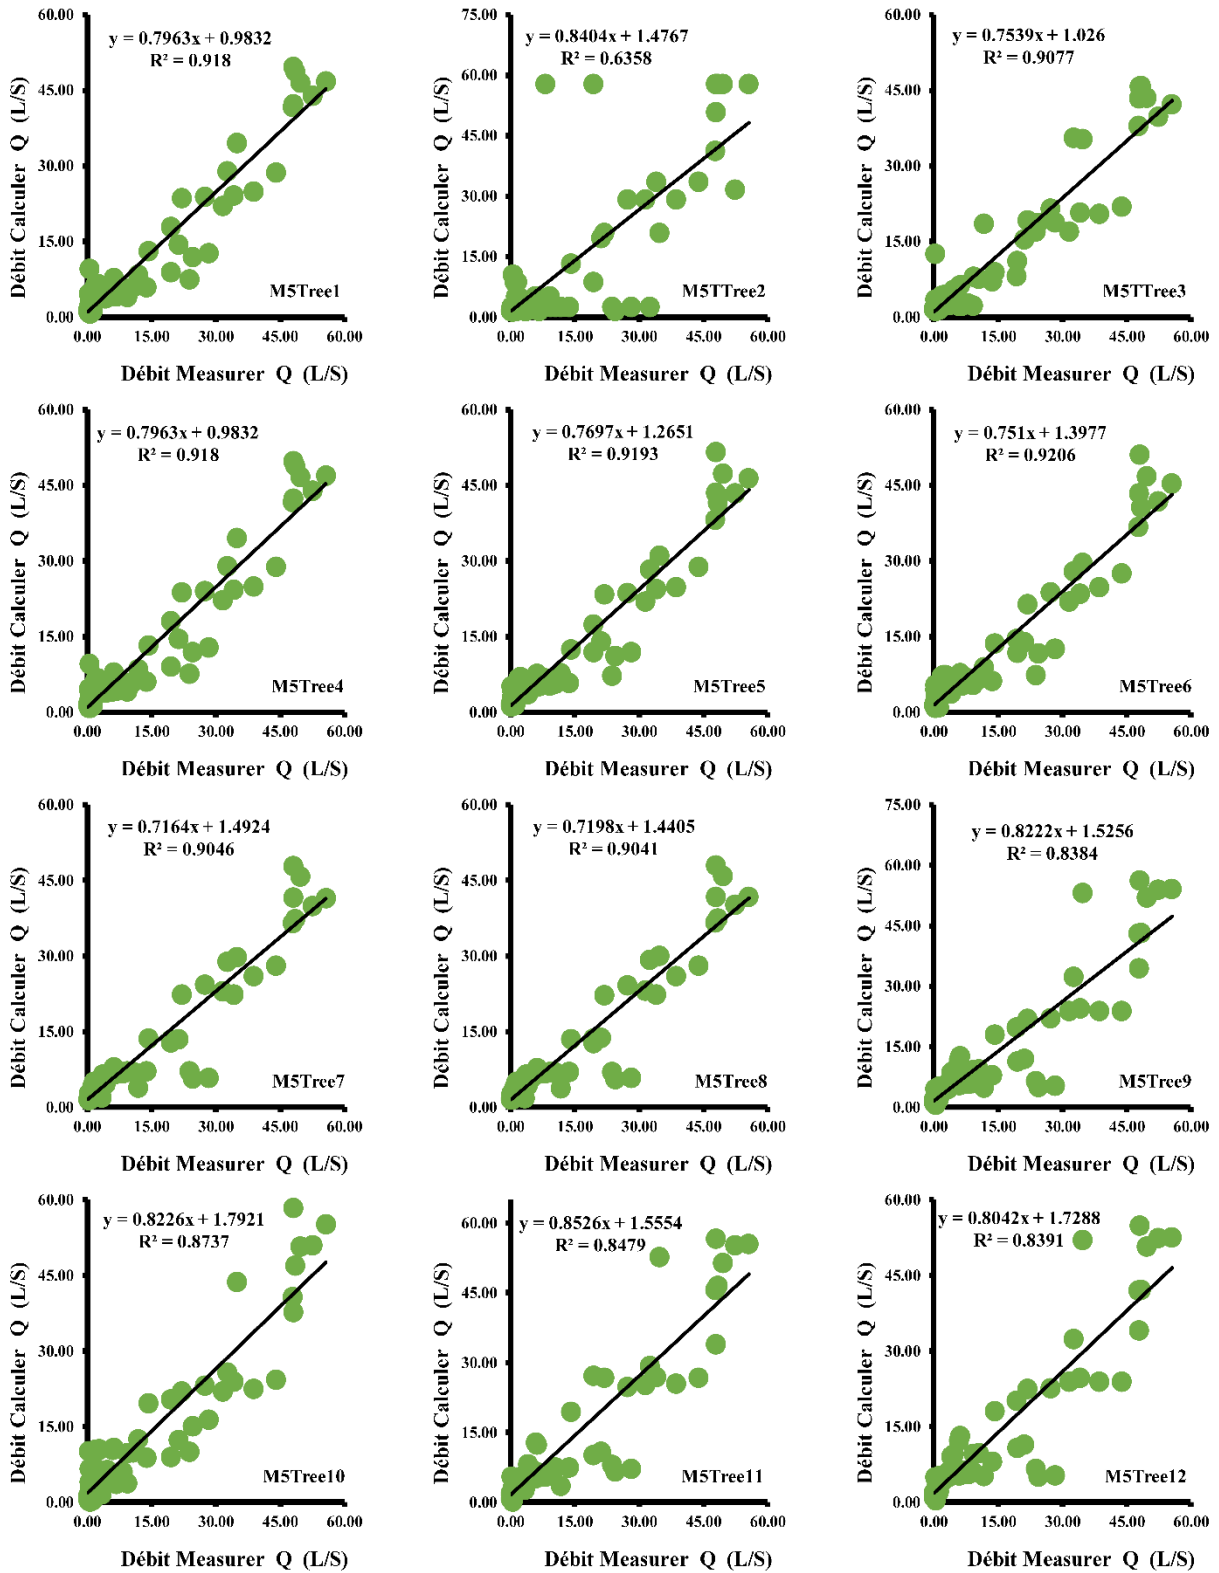


Figure VII. 3. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles M5Tree: barrage Bougous & phase de validation.

En phase d'apprentissage, MARS1 a démontré une performance exceptionnelle, illustrée par un coefficient R de 0.993, un NSE de 0.987, un RMSE de 1.867 et MAE de 1.345. En revanche, MARS2 a affiché des résultats moins satisfaisants avec un R de 0.914, un NSE de 0.835, un RMSE de 6.646 et un MAE de 4.795, indiquant une efficacité et une corrélation plus modérées. MARS3 a enregistré des performances étroitement parallèles à MARS1, obtenant un R de 0.992, un NSE de 0.984, un RMSE de 2.057 et un MAE de 1.463. MARS4 et MARS5 ont présenté des résultats robustes, chacun avec un R de 0.985, un NSE de 0.970, un RMSE de 2.826 et un MAE de 1.940. MARS6 a affiché des métriques de R=0.991, NSE=0.983, RMSE=2.140 et MAE=1.519, mettant en évidence sa capacité prédictive. Les modèles intermédiaires, à savoir MARS7 et MARS11, ont montré d'excellentes performances. MARS7 a obtenu un R de 0.960, un NSE de 0.921, un RMSE de 4.610 et un MAE de 3.449, tandis que MARS11 a rapporté des valeurs de R=0.946, NSE=0.894, RMSE=5.327, MAE=3.562. Les modèles MARS8 à MARS10 ont démontré des performances cohérentes, avec des valeurs de R entre 0.985-0.990, des NSE de 0.970-0.979, des RMSE autour de 2.50-2.80 et des MAE de 1.628-1.849. Enfin, MARS12 a produit un R de 0.977, un NSE de 0.955, un RMSE de 3.471 et un MAE de 2.373, démontrant sa fiabilité malgré des écarts légèrement plus élevés que les modèles les plus performants. Pour résumer, la phase d'apprentissage a révélé des disparités de performance entre les modèles MARS. MARS1 et MARS3 se sont distingués comme les leaders, soulignant l'importance de combiner des données temporelles avec des données piézométriques complètes. Les performances de MARS2 mettent en évidence la nécessité d'affiner l'intégration des données. Une analyse globale souligne la criticité de la sélection judicieuse des entrées pour maximiser la prédictivité des modèles.


En phase de validation, MARS1 a présenté des performances robustes avec des métriques de R=0.963 et de NSE=0.904. Cependant, son RMSE de 5.059 et son MAE de 3.289 ont mis en évidence certaines divergences dans les prédictions. En revanche, les performances réduites de MARS2 étaient manifestes, affichant un R de 0.755, un NSE de 0.538, un RMSE de 11.093 et un MAE de 7.940. MARS3 a donné un R de 0.920, un NSE de 0.843, un RMSE de 6.458 et un MAE de 4.519, suggérant une performance soutenue mais avec une légère variance. Les modèles MARS4 et MARS5 ont systématiquement affiché un R de 0.934, un NSE de 0.864, un RMSE de 6.027 et un MAE de 4.258. Les résultats de MARS6 ont révélé un R de 0.917, un NSE de 0.786, un RMSE de 7.553 et un MAE de 5.007, indiquant un écart de prédiction légèrement plus important. En ce qui concerne les métriques de MARS7, avec R=0.886, NSE=0.781, RMSE=7.636 et MAE=5.354, une divergence notable dans les prédictions est apparente. Les modèles MARS8 à MARS10 ont maintenu des performances robustes, affichant des valeurs de R entre 0.947 et 0.955, des NSE de 0.868 à 0.899, des RMSE de 5.179 à 5.925 et des MAE compris entre 3.489 et 4.258. MARS11 a présenté un R de 0.886, un NSE de 0.783, un RMSE de 7.607 et un MAE de 5.561, indiquant une légère diminution des performances par rapport à certains modèles comparables. En revanche, MARS12, avec un R de 0.944, un NSE de 0.887, un RMSE de 5.481 et un MAE de 3.551, a souligné sa capacité prédictive fiable. Pour résumer, la phase de validation a mis en lumière les disparités dans les performances des modèles MARS. Tandis que MARS1 et MARS3 sont restés en tête, l'efficacité réduite de MARS2 a souligné les risques liés à l'exclusion de variables temporelles malgré l'abondance de données piézométriques. Des modèles tels que MARS9 à MARS12 ont mis en avant les avantages d'une sélection stratégique des entrées. L'enseignement principal est la nécessité d'un équilibre dans les modèles basés sur l'IA, garantissant à la fois précision et efficacité, en mettant en avant la valeur de jeux de données à la fois étendus et pertinents.

En phase d'apprentissage, une analyse des douze M5Tree modèles a révélé des différences notables dans leur capacité à représenter les dynamiques d'infiltration du barrage. L'objectif de cette analyse était de déterminer la combinaison optimale des variables d'entrée par rapport aux résultats observés. Le modèle M5Tree2 a affiché les meilleures performances, avec un R de 0.981 et un indice NSE de 0.962. Sa précision est vérifiée par un RMSE de 3.192 l/s et un MAE de 1.921 l/s. Ces performances remarquables sont attribuées à l'inclusion de toutes les six mesures piézométriques (PZ1-PZ6) ainsi qu'au niveau d'eau dans le réservoir (CPE). En revanche, le modèle M5Tree a montré des performances relativement médiocres, affichant un R de 0.945, un NSE de 0.887, un RMSE de 5.515 l/s et un MAE de 3.630 l/s. Ceci est principalement dû à son utilisation limitée des données, se basant uniquement sur la date, PZ3, et le niveau d'eau (CPE), ce qui suggère une incapacité à saisir efficacement les processus d'infiltration. Les modèles M5Tree1 et M5Tree4 ont produit des résultats similaires, affichant tous deux un R de 0.973 et un NSE de 0.943. Cette concordance, malgré des ensembles de variables piézométriques différents, suggère une importance équivalente ou une compensation mutuelle entre les différentes variables. En revanche, les modèles M5Tree9 et M5Tree11, qui se sont basés sur des variables piézométriques spécifiques, ont affiché des performances inférieures, avec des valeurs R de 0.952 et 0.950, et des valeurs NSE de 0.896 et 0.889, respectivement. Ces résultats soulignent la valeur d'un ensemble de données piézométriques plus complet. En conclusion, nos résultats mettent en évidence l'importance de la diversité des variables d'entrée dans la modélisation de débit des fuites. Bien que le modèle M5Tree2 se démarque par ses performances exceptionnelles, des modèles comme M5Tree1 et M5Tree4 ont également produit des résultats satisfaisants. Cependant, il est essentiel de faire preuve de prudence lors de la sélection d'un modèle pour éviter le surajustement et garantir une meilleure généralisation.


Au cours de la phase de validation, les métriques de performance ont fourni des informations précieuses. Les modèles M5Tree1 et M5Tree4 ont affiché une performance solide, avec des valeurs de R identiques à 0.958 et des valeurs d'efficacité NSE de 0.893. Leur stabilité tout au long des phases d'apprentissage et de validation indique une robustesse, confirmée par leurs valeurs de RMSE et de MAE, qui se situent respectivement à 5.325 l/s et 3.608 l/s. En revanche, le modèle M5Tree2, qui avait brillé pendant la phase d'apprentissage, a connu une baisse de performance lors de la validation, comme en témoignent ses valeurs de R à 0.797, de NSE à 0.569, de RMSE à 10.709 l/s et de MAE à 5.945 l/s. Cette disparité suggère un potentiel de surajustement pendant la phase d'apprentissage. Parmi les modèles utilisant des entrées piézométriques spécifiques, M5Tree9 et M5Tree11 ont obtenu des performances similaires, avec des valeurs de R à 0.916 et 0.921, des valeurs de NSE à 0.837 et 0.848, ainsi que des RMSE et MAE aux alentours de 6.5 l/s et 4.3 l/s, respectivement. M5Tree10, quant à lui, a présenté de légèrement meilleures métriques, affichant un R de 0.935, un NSE de 0.870, un RMSE de 5.878 l/s et un MAE de 4.143 l/s. Le modèle M5Tree12, qui se base uniquement sur les composants de la date et du niveau d'eau (CPE), a montré un R de 0.916, un NSE de 0.836, un RMSE de 6.606 L/S et un MAE de 4.325 L/S. Ces valeurs soulignent l'importance des données piézométriques. En conclusion, la phase de validation a révélé la stabilité et l'adaptabilité des modèles face à de nouvelles données. M5Tree1 et M5Tree4 ont démontré une cohérence, tandis que la baisse de performance du modèle M5Tree2 met en évidence les risques de surajustement. Les résultats mitigés des modèles se concentrant sur des entrées piézométriques spécifiques mettent en évidence l'importance de la diversité des données. Cette

étude souligne la nécessité d'une sélection minutieuse des variables d'entrée et l'importance d'utiliser plusieurs points de données piézométriques pour prédire le débit des fuites avec précision.

- 1) Les modèles LSSVM ont constamment affiché une performance supérieure, en particulier pendant la phase d'apprentissage. Leur capacité à généraliser a également été confirmée par leurs robustes performances de validation. Cela suggère que les modèles LSSVM pourraient être mieux adaptés pour capturer la dynamique sous-jacente du débit des fuites à travers le barrage de Bougous, comparativement aux modèles MARS et M5Tree.
- 2) Les modèles MARS ont montré une variabilité considérable dans leurs métriques de performance. Alors que certains modèles MARS ont obtenu des performances louables, d'autres ont nettement sous-performé, indiquant que la performance de cette méthode pourrait être hautement sensible aux caractéristiques d'entrée spécifiquement sélectionnées.
- 3) Les modèles M5Tree, en revanche, ont fourni des résultats relativement cohérents à travers différentes combinaisons d'entrées. Bien qu'ils n'aient pas atteint la performance maximale des modèles LSSVM, leur fiabilité à travers diverses configurations suggère une approche de modélisation stable, voire prometteuse.
- 4) Des modèles plus simples (avec moins d'entrées), tels que LSSVM8 et LSSVM12, ont bien fonctionné, indiquant que davantage de complexité n'entraîne pas nécessairement une meilleure performance prédictive.
- 5) Le niveau d'eau dans le réservoir (CPE) s'est révélé être un facteur potentiellement crucial. En examinant des modèles tels que LSSVM12 et M5Tree12, qui se sont principalement basés sur les données temporelles et le CPE, nous pouvons déduire l'importance des niveaux du réservoir dans la modélisation du débit des fuites.
- 6) Les résultats obtenus sont schématisés par deux types de figures: les Boxplot & Violinplot (**Figure VII.4**) et le diagram de Taylor (**Figure VII.5**).



**Figure VII. 4.** Comparaison entre les différents modèles ensemblistes par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Bougous.



**Figure VII. 5.** Le diagramme de Taylor pour la comparaison entre les meilleurs ANN modèles : Barrage Bougous.

#### VII.4. Résultats Obtenus par les Modèles Ensemblistes : Barrage Cheurfas

Le **Tableau VII.2** comporte les résultats de modélisation par les modèles Ensembliste pour le barrage Cheurfas. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents modèles Ensembliste (barrage bougouss) sont reportés dans la **Figure VII.6-8**. En phase d'apprentissage, le modèle LSSVM1, combinant calendrier, données piézométriques et CPE, a montré des performances robustes avec R de 0.993, NSE de 0.984, RMSE de 0.272 et MAE de 0.179. Le modèle LSSVM2, sans données de calendrier, a connu une légère baisse de performance avec R de 0.964, NSE de 0.929, RMSE de 0.581 et MAE de 0.301. LSSVM3, avec des données de calendrier mais sans CPE, a enregistré un R de 0.992, NSE de 0.984, RMSE de 0.273 et MAE de 0.183. Le LSSVM4, qui a utilisé des entrées piézométriques sélectives, a rapporté d'excellentes performances R de 0.996, NSE de 0.992, RMSE de 0.193 et MAE de 0.121. Les modèles LSSVM5 et LSSVM6, avec une diminution des entrées piézométriques, avaient des valeurs R de 0.990 et 0.992 respectivement, avec des RMSE et MAE montrant de légères variations. Les modèles LSSVM7 à LSSVM9, avec des entrées simplifiées, ont néanmoins affiché des résultats exceptionnels, en particulier LSSVM8 avec un RMSE de 0.111 et un MAE de 0.063. Les modèles LSSVM10 à LSSVM12 ont montré que même avec moins d'entrées piézométriques, une bonne performance peut être obtenue, en particulier LSSVM11 avec R de 0.999, NSE de 0.998, RMSE de 0.090 et MAE de 0.058. Les principaux enseignements de la phase d'apprentissage indiquent une sensibilité du modèle aux structures d'entrée. La présence de données de calendrier aux côtés de lectures piézométriques spécifiques a grandement influencé la précision. Bien que le CPE ait constamment affecté les résultats du modèle, son exclusion n'était pas préjudiciable, reflétant la résilience du modèle. Pour résumer, LSSVM8 et LSSVM11 se sont démarqués par leur précision et leurs erreurs minimales pendant l'apprentissage. LSSVM2, bien qu'efficace, semblait être le moins optimisé. Les données suggèrent que le choix des bonnes entrées est essentiel, avec un potentiel d'optimisation même dans des scénarios d'entrée réduits.

Pendant la phase de validation, nous avons évalué l'efficacité des modèles LSSVM à l'aide de métriques de performance, visant à comprendre leur généralisation à de nouvelles données pour des prédictions dans le monde réel.

**Tableau VII. 2.** Performances des différents modèles Ensemblistes & barrage Cheurfas.

| Models   | Training |       |       |       | Validation |       |       |       |
|----------|----------|-------|-------|-------|------------|-------|-------|-------|
|          | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE  | MAE   |
| LSSVM1   | 0.993    | 0.984 | 0.272 | 0.179 | 0.968      | 0.931 | 0.482 | 0.343 |
| LSSVM2   | 0.964    | 0.929 | 0.581 | 0.301 | 0.955      | 0.912 | 0.546 | 0.347 |
| LSSVM3   | 0.992    | 0.984 | 0.273 | 0.183 | 0.962      | 0.917 | 0.527 | 0.376 |
| LSSVM4   | 0.996    | 0.992 | 0.193 | 0.121 | 0.970      | 0.933 | 0.475 | 0.332 |
| LSSVM5   | 0.990    | 0.980 | 0.312 | 0.220 | 0.963      | 0.921 | 0.515 | 0.385 |
| LSSVM6   | 0.992    | 0.984 | 0.277 | 0.187 | 0.965      | 0.927 | 0.495 | 0.363 |
| LSSVM7   | 0.999    | 0.997 | 0.125 | 0.075 | 0.929      | 0.840 | 0.734 | 0.496 |
| LSSVM8   | 0.999    | 0.997 | 0.111 | 0.063 | 0.922      | 0.828 | 0.761 | 0.492 |
| LSSVM9   | 0.999    | 0.997 | 0.125 | 0.075 | 0.929      | 0.840 | 0.733 | 0.496 |
| LSSVM10  | 0.991    | 0.982 | 0.290 | 0.197 | 0.967      | 0.933 | 0.475 | 0.354 |
| LSSVM11  | 0.999    | 0.998 | 0.090 | 0.058 | 0.954      | 0.898 | 0.587 | 0.385 |
| LSSVM12  | 0.999    | 0.997 | 0.119 | 0.069 | 0.922      | 0.830 | 0.758 | 0.490 |
| MARS1    | 0.942    | 0.887 | 0.733 | 0.527 | 0.948      | 0.894 | 0.596 | 0.460 |
| MARS2    | 0.945    | 0.894 | 0.710 | 0.484 | 0.939      | 0.878 | 0.640 | 0.477 |
| MARS3    | 0.933    | 0.870 | 0.784 | 0.607 | 0.890      | 0.792 | 0.838 | 0.713 |
| MARS4    | 0.942    | 0.887 | 0.733 | 0.527 | 0.948      | 0.894 | 0.596 | 0.460 |
| MARS5    | 0.942    | 0.887 | 0.733 | 0.527 | 0.948      | 0.894 | 0.596 | 0.460 |
| MARS6    | 0.982    | 0.964 | 0.416 | 0.301 | 0.957      | 0.915 | 0.536 | 0.417 |
| MARS7    | 0.935    | 0.874 | 0.772 | 0.516 | 0.934      | 0.869 | 0.665 | 0.474 |
| MARS8    | 0.942    | 0.887 | 0.734 | 0.499 | 0.932      | 0.867 | 0.670 | 0.483 |
| MARS9    | 0.959    | 0.919 | 0.621 | 0.443 | 0.926      | 0.855 | 0.699 | 0.500 |
| MARS10   | 0.982    | 0.965 | 0.406 | 0.290 | 0.950      | 0.902 | 0.574 | 0.424 |
| MARS11   | 0.931    | 0.866 | 0.796 | 0.600 | 0.938      | 0.874 | 0.652 | 0.463 |
| MARS12   | 0.936    | 0.876 | 0.766 | 0.530 | 0.893      | 0.795 | 0.830 | 0.553 |
| M5Tree1  | 0.960    | 0.921 | 0.611 | 0.338 | 0.951      | 0.903 | 0.572 | 0.400 |
| M5Tree2  | 0.954    | 0.909 | 0.659 | 0.379 | 0.933      | 0.868 | 0.667 | 0.471 |
| M5Tree3  | 0.928    | 0.859 | 0.817 | 0.445 | 0.913      | 0.827 | 0.764 | 0.494 |
| M5Tree4  | 0.960    | 0.921 | 0.611 | 0.338 | 0.951      | 0.903 | 0.572 | 0.400 |
| M5Tree5  | 0.960    | 0.921 | 0.611 | 0.338 | 0.951      | 0.903 | 0.572 | 0.400 |
| M5Tree6  | 0.958    | 0.919 | 0.621 | 0.326 | 0.947      | 0.895 | 0.595 | 0.382 |
| M5Tree7  | 0.953    | 0.901 | 0.687 | 0.414 | 0.890      | 0.791 | 0.839 | 0.541 |
| M5Tree8  | 0.966    | 0.925 | 0.595 | 0.355 | 0.887      | 0.777 | 0.866 | 0.543 |
| M5Tree9  | 0.953    | 0.901 | 0.687 | 0.414 | 0.890      | 0.791 | 0.839 | 0.541 |
| M5Tree10 | 0.958    | 0.919 | 0.621 | 0.326 | 0.947      | 0.895 | 0.595 | 0.382 |
| M5Tree11 | 0.940    | 0.882 | 0.749 | 0.453 | 0.911      | 0.821 | 0.777 | 0.508 |
| M5Tree12 | 0.959    | 0.912 | 0.648 | 0.386 | 0.885      | 0.778 | 0.864 | 0.555 |

Le modèle LSSVM1, qui a combiné le calendrier grégorien, les données piézométriques complètes, et le CPE, a affiché une performance exceptionnelle: R de 0.968, NSE de 0.931, RMSE de 0.482, et MAE de 0.343. LSSVM2, excluant les données du calendrier et se concentrant sur les données piézométriques et le CPE, a enregistré une baisse de performance avec R de 0.955, NSE de 0.912, RMSE de 0.546, et MAE de 0.347, suggérant l'importance du calendrier. Le LSSVM3, réintégrant le calendrier mais excluant la CPE, a montré un R de 0.962, NSE de 0.917, RMSE de 0.527, et MAE de 0.376, mettant en évidence le rôle de la CPE dans la précision de la prédiction. LSSVM4, a obtenu les métriques supérieures: R de 0.970, NSE de

0.933, RMSE de 0.475, et MAE de 0.332. LSSVM5 et LSSVM6, avec des données piézométriques réduites, ont affiché des valeurs R de 0.963 et 0.965 respectivement, et des scores RMSE et MAE variables. LSSVM7 à LSSVM9, avec des entrées plus simples, ont néanmoins affiché des chiffres remarquables, en particulier LSSVM8 avec un RMSE de 0.111 et un MAE de 0.063. Les LSSVM10 à LSSVM12, simplifiant davantage les entrées, ont démontré des performances variées. Notamment, le LSSVM11, malgré moins d'entrées, a affiché un R de 0.954, NSE de 0.898, RMSE de 0.487, et MAE de 0.385. Le LSSVM12, étant le plus minimaliste, a conservé de hautes métriques: R de 0.999, NSE de 0.997, RMSE de 0.119, et MAE de 0.069. L'analyse souligne que les modèles LSSVM4 et LSSVM10 performant constamment bien. Ces métriques guident les parties prenantes dans la sélection d'un modèle approprié, soulignant la nécessité d'un choix méticuleux du modèle en fonction de l'application et de l'ensemble de données.

Au cours de la phase d'apprentissage des modèles MARS, nous avons évalué diverses combinaisons d'entrées pour déterminer leur impact sur les performances. Parmi ces combinaisons, MARS1, MARS4 et MARS5 ont présenté des métriques de performance similaires, avec un coefficient R de 0.942 et un coefficient d'efficacité NSE de 0.887, montrant une précision prédictive élevée. Toutefois, des différences subsistent, comme en témoignent le RMSE de 0.733 et MAE de 0.527. Le modèle MARS2, en excluant les données du calendrier grégorien, a présenté de meilleures performances avec un coefficient R de 0.945, un coefficient NSE de 0.894, une RMSE de 0.710 et une MAE de 0.484, suggérant ainsi une amélioration des capacités prédictives. En revanche, MARS3, qui intègre des données piézométriques sans inclure le niveau d'eau dans le réservoir, a sous-performé par rapport aux modèles initiaux. Ses métriques comprennent un R de 0.933, un NSE de 0.870, un RMSE de 0.784 et un MAE de 0.607, indiquant une précision réduite en l'absence de CPE. En contraste, MARS6 a démontré une performance exceptionnelle avec un R de 0.982 et un NSE de 0.964, ce qui témoigne d'une précision prédictive remarquable. De plus, avec un RMSE aussi bas que 0.416 et un MAE de 0.301, il s'est rapproché au maximum des valeurs réelles. Les modèles MARS7 à MARS12, qui ont utilisé des données piézométriques limitées ainsi que des entrées constantes pour le calendrier et le niveau du réservoir, ont affiché des résultats variés. Alors que MARS7 et MARS8 étaient étroitement alignés sur les métriques de MARS1, une diminution de performance a été observée de MARS9 à MARS12, notamment en ce qui concerne le NSE, ce qui suggère une précision réduite avec moins de points de données piézométriques.

En phase de validation, MARS1, MARS4 et MARS5 ont affiché des résultats cohérents. Avec un coefficient R de 0.948, ces modèles ont atteint la corrélation la plus élevée parmi les douze. Leur efficacité NSE de 0.894, bien que remarquable, a été surpassé par MARS6, tandis que leurs valeurs de RMSE et de MAE de 0.596 et 0.460 respectivement confirment une performance stable de l'apprentissage à la validation. En revanche, MARS2 a enregistré une légère baisse du R à 0.939 et du NSE à 0.878, suggérant une performance légèrement réduite par rapport à MARS1, MARS4 et MARS5. MARS3 a connu une chute plus significative lors de la phase de validation, avec des valeurs de R de 0.890 et de NSE de 0.792, le plaçant avant-dernier parmi les modèles. Des valeurs de RMSE et de MAE plus élevées indiquent une robustesse réduite. MARS6 a continué à briller en validation. Malgré un R réduit à 0.957, il a conservé le NSE le plus élevé à 0.915 et a enregistré les valeurs de RMSE et de MAE les plus basses. Les modèles MARS7 à MARS12, ont connu une baisse de performance avec la réduction des points de données piézométriques. MARS12, qui utilise le moins de données,

avait un R de 0.893, le NSE le plus bas à 0.795, et des valeurs de RMSE et de MAE plus élevées. En validation, MARS6 s'est distingué par son mix optimal de données d'entrée, aboutissant au meilleur équilibre entre corrélation et précision prédictive. Cependant, des modèles comme MARS3 et MARS12, avec des variables omises ou minimales, ont montré une efficacité réduite. Il est intéressant de noter que les métriques identiques de MARS1, MARS4 et MARS5 suggèrent une redondance de données ou une compensation mutuelle entre les ensembles de données piézométriques. En conclusion, la phase de validation met en évidence l'importance cruciale des données piézométriques et du CPE dans la prédiction des infiltrations. Alors que MARS6, en intégrant les données du calendrier, les données piézométriques clés et le niveau d'eau du réservoir, s'est avéré être le meilleur performeur dans les deux phases, des modèles comme MARS3 et MARS12, avec des variables omises ou minimales, ont montré des performances inférieures. Cela suggère la nécessité d'un ensemble de données équilibré pour une prédiction optimale des infiltrations en utilisant l'approche IA de MARS.

En abordant l'approche M5Tree, lors de la phase d'apprentissage, divers modèles ont été évalués en fonction de leurs performances, dont les détails sont les suivants. M5Tree1 a affiché d'impressionnantes métriques avec un coefficient R de 0.960, un NSE de 0.921, un RMSE de 0.611 et un MAE de 0.338, démontrant une forte corrélation et une précision notable dans les prédictions. M5Tree2, bien que robuste, a légèrement sous-performé par rapport à M5Tree1 avec un R de 0.954, un NSE de 0.909, un RMSE de 0.659 et un MAE de 0.379, indiquant un ajustement légèrement moins précis. M5Tree3 a enregistré des métriques de R de 0.928, de NSE de 0.859, de RMSE de 0.817 et de MAE de 0.445, révélant une efficacité et une corrélation plus faibles par rapport à ses prédécesseurs. Tant que M5Tree4 et M5Tree5 ont affichés les performances: R=0.960, NSE=0.921, RMSE=0.611 et MAE=0.338, confirmant une efficacité et une corrélation remarquables. M5Tree6 ressemblait étroitement à M5Tree1, M5Tree4 et M5Tree5 avec des métriques de R de 0.958, de NSE de 0.919, RMSE de 0.621 et de MAE de 0.326, bien qu'avec un RMSE légèrement plus élevé. M5Tree7 et M5Tree9 ont partagé des résultats similaires, avec un R de 0.953, un NSE de 0.901, un RMSE de 0.687 et un MAE de 0.414, indiquant une modélisation de qualité mais pas au niveau des meilleurs modèles de cette phase. M5Tree8 a surpassé tous les autres avec le R le plus élevé à 0.966, un NSE de 0.925, et des valeurs plus faibles de RMSE (0.595) et de MAE (0.355), ce qui en fait le meilleur en termes de capacités prédictives pendant l'apprentissage. Les métriques de M5Tree10, identiques à celles de M5Tree6, comprenaient un R de 0.958, un NSE de 0.919, un RMSE de 0.621 et un MAE de 0.326, mettant en avant sa performance robuste. M5Tree11 a affiché un R de 0.940, un NSE de 0.882, un RMSE de 0.749 et un MAE de 0.453, suggérant une légère baisse de la précision des prédictions. M5Tree12 a présenté de bonnes métriques avec un R de 0.959, un NSE de 0.912, un RMSE de 0.648 et un MAE de 0.386, bien qu'il n'ait pas été le leader dans aucune métrique. En résumé, M5Tree8 était le modèle le plus performant de cette phase, tandis que M5Tree3 était en queue de peloton.

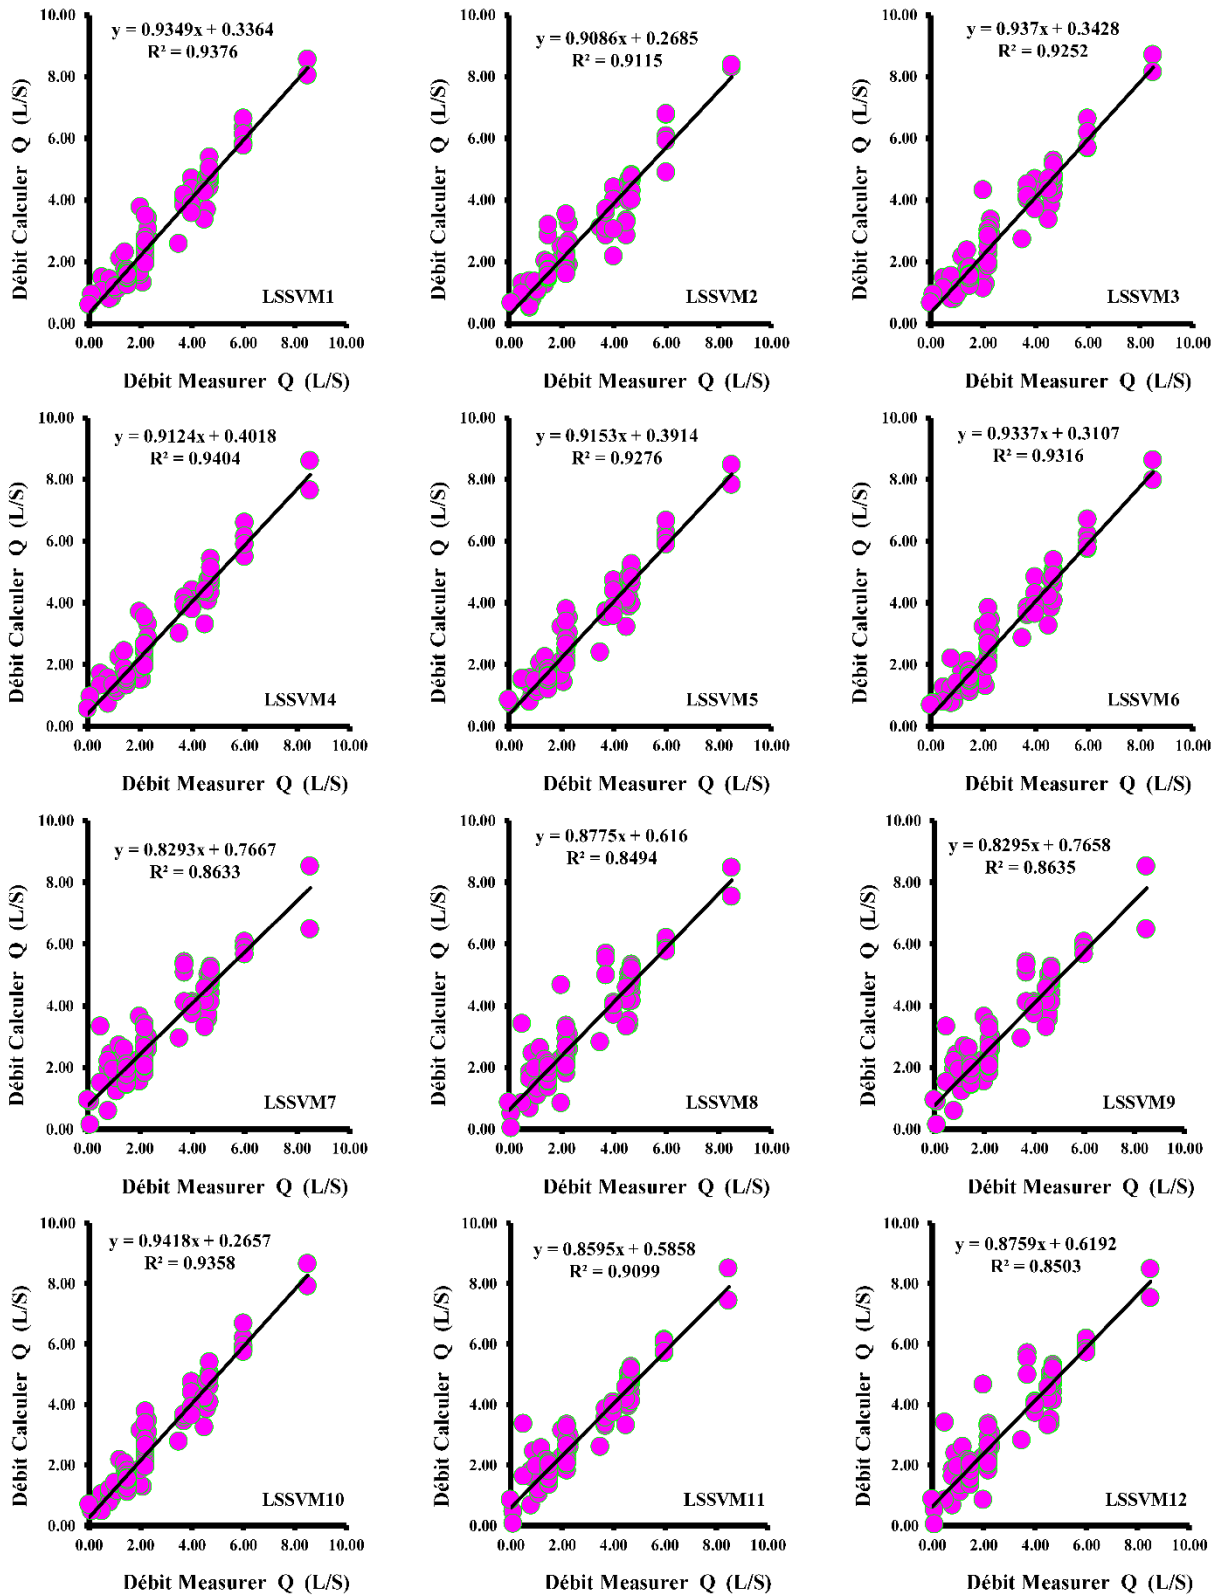


Figure VII. 6. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles LSSVM: barrage Cheurfas & phase de validation.

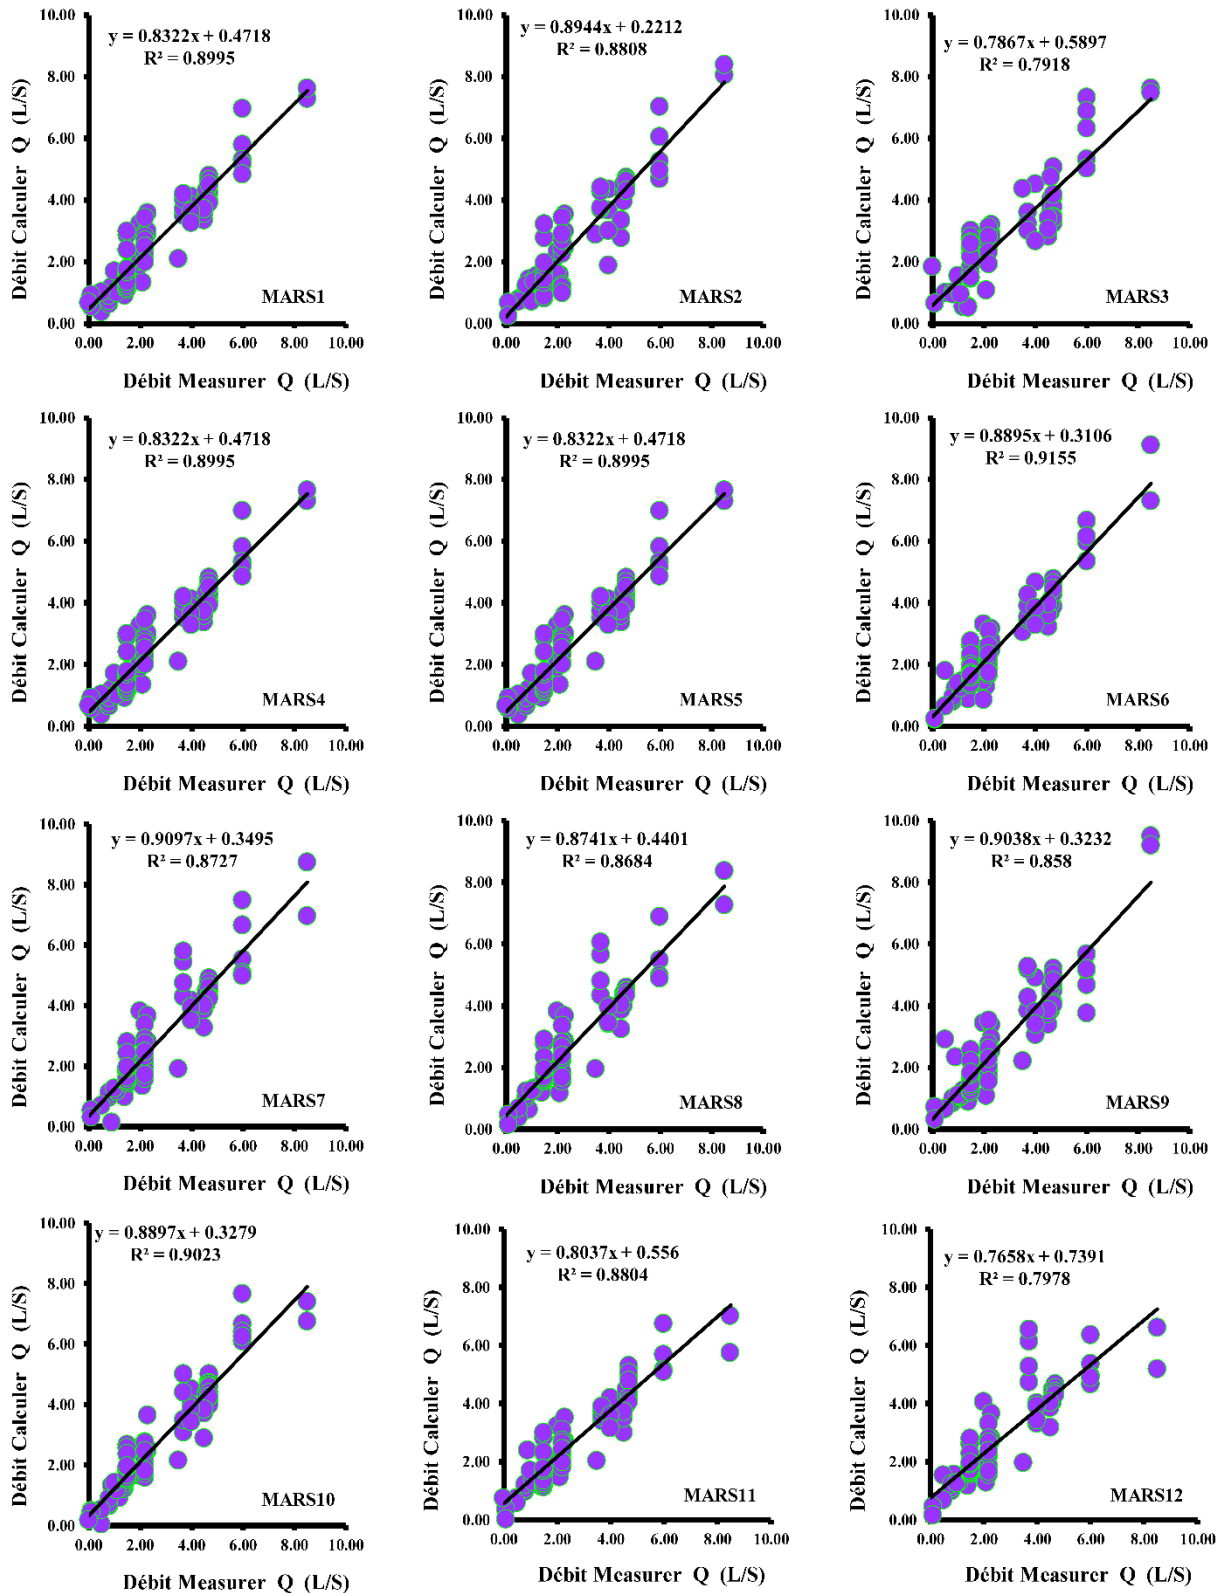


Figure VII. 7. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles MARS: barrage Cheurfas & phase de validation.

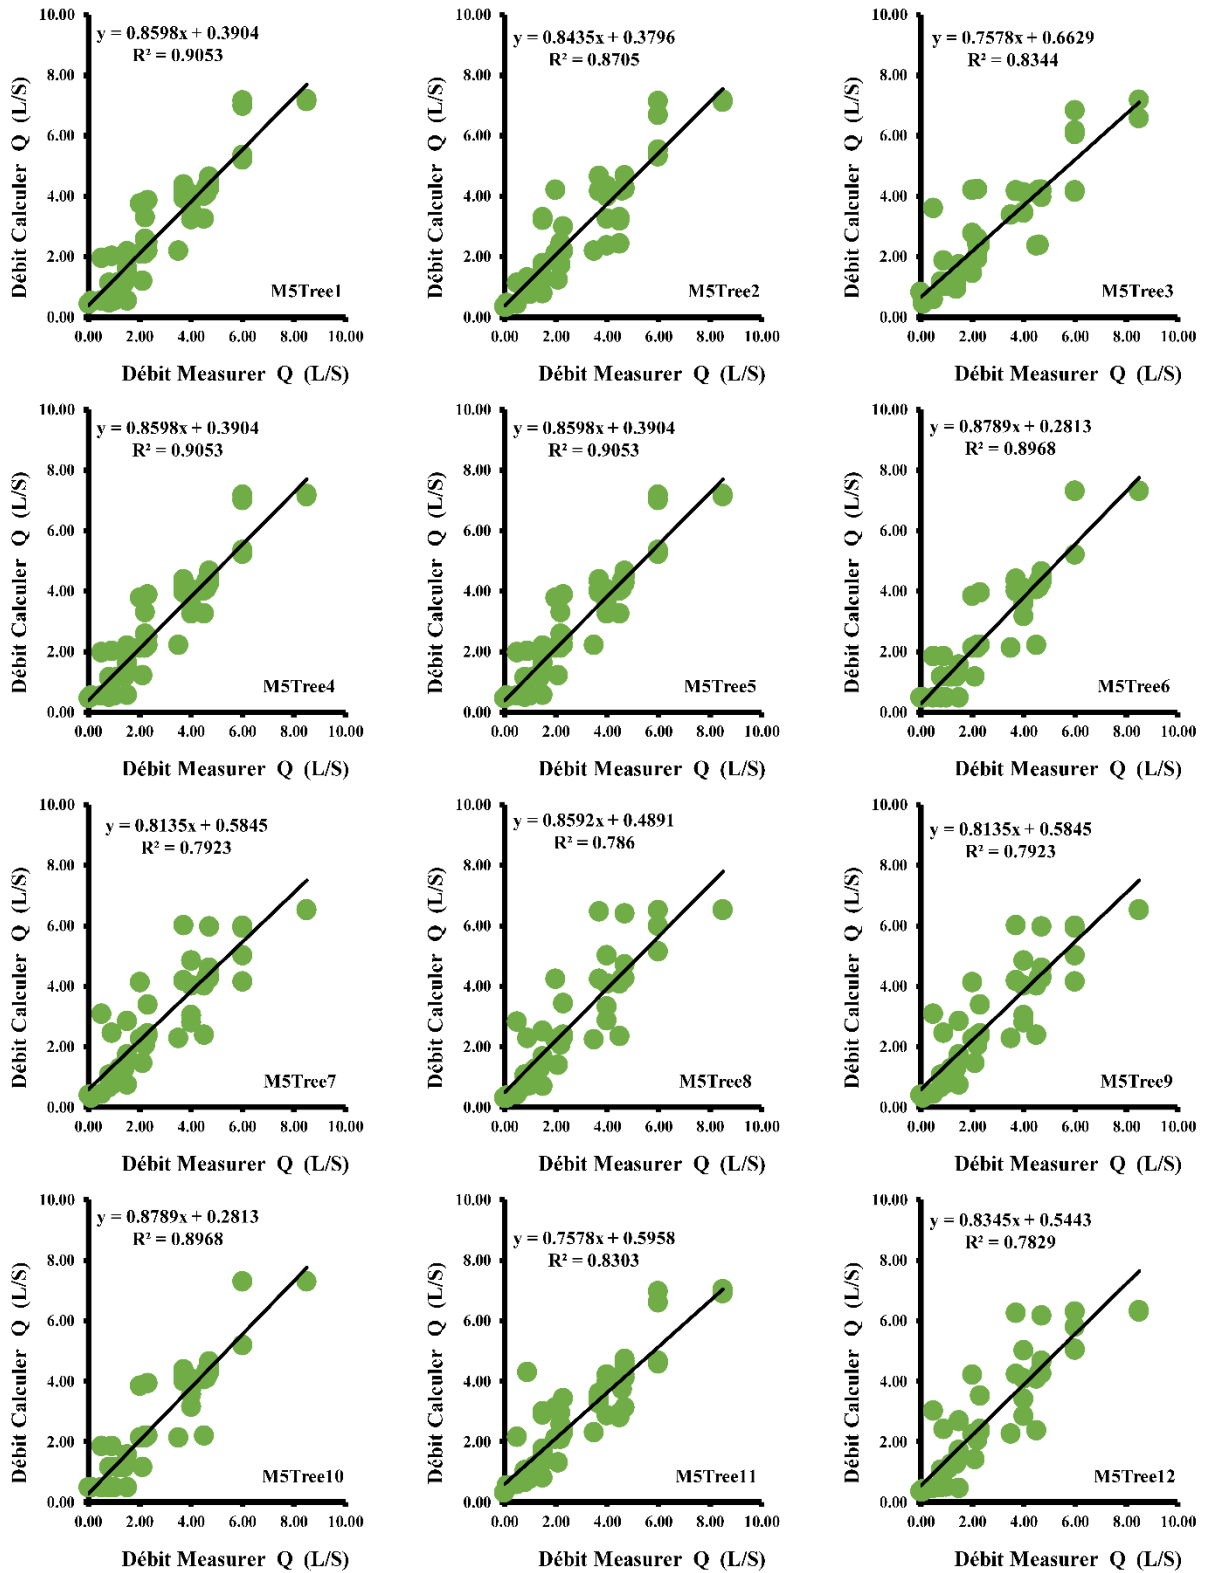


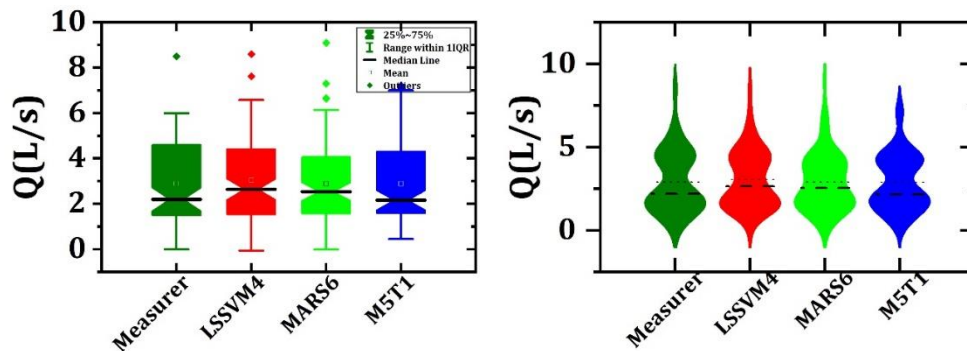
Figure VII. 8. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles M5Tree : barrage Cheurfas & phase de validation.

En phase de validation, différents modèles ont été évalués et leurs métriques de performance ont été analysées, comme résumé dans les paragraphes suivants. M5Tree1, M5Tree4 et M5Tree5 se sont distingués avec des métriques identiques:  $R=0.951$ ,  $NSE=0.903$ ,  $RMSE=0.572$  et  $MAE=0.400$ , reflétant une forte efficacité et une corrélation notable. En comparaison, les métriques de M5Tree2 ( $R=0.933$ ,  $NSE=0.868$ ,  $RMSE=0.667$ ,  $MAE=0.471$ ) suggèrent une efficacité légèrement réduite. M5Tree3 a affiché des métriques de  $R$  de 0.913, de  $NSE$  de 0.827, de  $RMSE$  de 0.764 et de  $MAE$  de 0.494, indiquant une baisse de performance. M5Tree6, avec un  $R$  de 0.947, un  $NSE$  de 0.895, un  $RMSE$  de 0.595 et un  $MAE$  de 0.382, a mis en évidence sa précision, en particulier compte tenu de ses métriques d'erreur minimales. En revanche, M5Tree7 et M5Tree9, avec des métriques de  $R$  de 0.890, de  $NSE$  de 0.791, de  $RMSE$  de 0.839 et de  $MAE$  de 0.541, ont montré une efficacité réduite lors de la validation. Malgré les performances remarquables de M5Tree8 lors de l'apprentissage, il a accusé un retard lors de la validation, enregistrant des valeurs de  $R$  de 0.887, de  $NSE$  de 0.777, de  $RMSE$  de 0.866 et de  $MAE$  de 0.543. Les résultats de M5Tree10 reflétaient ceux de M5Tree6, démontrant une corrélation et une efficacité robustes. M5Tree11 s'est présenté avec  $R=0.911$ ,  $NSE=0.821$ ,  $RMSE=0.777$  et  $MAE=0.508$ , signifiant une bonne performance mais sans être en tête. M5Tree12 a légèrement peiné, indiquant une efficacité plus faible avec  $R=0.885$ ,  $NSE=0.778$ ,  $RMSE=0.864$  et  $MAE=0.555$ . M5Tree6 s'est distingué comme le modèle le mieux performant lors de la phase de validation grâce à ses métriques équilibrées. D'autre part, M5Tree7, M5Tree9, et surtout M5Tree8 ont sous-performé, comme le suggèrent leurs valeurs d'erreur élevées. La différence de performance entre l'apprentissage et la validation souligne le besoin de généralisation des modèles et les risques de surajustement potentiel avec certaines combinaisons de paramètres d'entrée. Il est évident que des points de données piézométriques spécifiques peuvent influencer considérablement les capacités prédictives. Équilibrer la complexité du modèle avec sa généralisation est essentiel pour garantir une performance constante à travers les jeux de données, comme le montre la disparité entre les phases pour des modèles comme M5Tree8. Les efforts de modélisation futurs devraient prioriser cet équilibre.


En résumé on peut conclure ce qui suit :

- 1) Dans l'analyse comparative des approches de modélisation, le LSSVM n'a pas seulement surpassé constamment le MARS et le M5Tree, mais a également démontré une solution robuste pour le problème considéré, comme en témoignent ses valeurs supérieures de  $R$  et  $NSE$ , des valeurs  $RMSE$  et  $MAE$  plus basses, ainsi que sa capacité exceptionnelle à aligner étroitement les valeurs prédites avec les valeurs observées, garantissant une haute précision dans les prévisions des écoulements de débit des fuites.
- 2) Bien que le LSSVM dépasse constamment les deux autres modèles en termes de valeurs  $R$  et  $NSE$ , ce qui suggère un possible surajustement ou une capacité de généralisation réduite du MARS et du M5Tree, en particulier pendant la phase de validation, il est crucial de reconnaître que le MARS excelle dans certaines combinaisons d'entrées spécifiques. Par exemple, il montre d'excellentes performances lorsque la date est entrelacée avec plusieurs points piézométriques, comme c'est le cas dans MARS6. En revanche, le M5Tree maintient de bonnes performances avec des entrées variées, allant des combinaisons complexes de M5T1, à des configurations plus simples comme M5T12.

- 3) Lors de l'analyse de l'influence des données du calendrier Grégorien sur la modélisation, l'exclusion des paramètres du calendrier grégorien dans M2, par rapport à M1, réduit les performances, en particulier dans le cadre du LSSVM. Bien que ces paramètres puissent indiquer des influences saisonnières sur le débit des fuites, leur présence n'améliore pas systématiquement les résultats des modèles. La combinaison des données calendaires avec des lectures piézométriques spécifiques souligne leur importance contextuelle, tandis que l'inclusion récurrente de ces données à travers les modèles souligne la nécessité synergique des facteurs temporels pour des prédictions de débit des fuites précises.
- 4) La simplicité peut souvent rivaliser avec la complexité. Par exemple, le LSSVM12, utilisant uniquement des données temporelles et CPE, atteint des mesures de performance comparables à certains des modèles les plus complexes. Ceci souligne l'idée que des modèles avec moins d'entrées, mais cruciales, peuvent toujours fournir des prédictions robustes, atténuant le potentiel de surajustement.
- 5) Les modèles englobant une gamme étendue de points de données piézométriques (PZ1 à PZ6) présentent généralement une performance améliorée à travers différentes approches IA, en particulier lorsqu'ils utilisent avec le niveau d'eau (CPE). De telles observations soulignent le rôle crucial de ces variables dans la prévision précise de l'écoulement de débit des fuites.



**Figure VII. 9.** Comparaison entre les différents modèles Ensemblistes par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Cheurfas.



**Figure VII. 10.** Le diagramme de Taylor pour la comparaison entre les meilleurs modèles Ensemblistes: Barrage Cheurfas.

## VII.5. Résultats Obtenus par les Modèles Ensemblistes : Barrage Zit Emba

Le **Tableau VII.3** comporte les résultats de la modélisation par les modèles Ensembliste pour le barrage Zit Emba. Les Scatterplots des valeurs des débits de fuite  $Q$  mesurées et calculées par les différents modèles ensembliste (barrage bougouss) sont reportés dans la **Figure VII.11-13**. En phase d'apprentissage, les variations de performance découlent des différences entre les variables d'entrée, notamment les paramètres de calendrier grégorien, les données piézométriques (PZ1 à PZ9) et le niveau d'eau du réservoir (CPE). Les résultats obtenus au cours de cette phase d'apprentissage ont démontré plusieurs remarques. Le modèle LSSVM1 présente une précision de modélisation modérée, avec une valeur R de 0.836 et un NSE de 0.686. Les valeurs RMSE et MAE sont respectivement de 0.867 et 0.655. Bien que ses entrées complètes offrent un ensemble riche de données, elles pourraient potentiellement introduire des informations superflues. En revanche, le LSSVM2, en éliminant les données de date, affiche des valeurs R et NSE de 0.828 et 0.684, avec des valeurs RMSE et MAE respectives de 0.870 et 0.639, ce qui met en évidence une performance comparable à celle de LSSVM1. En changeant de perspective, le LSSVM3, en évitant l'inclusion de CPE au profit des données de date et piézométriques, surpasse ses prédécesseurs avec un R de 0.885 et un NSE de 0.781. Les métriques RMSE et MAE du modèle sont respectivement de 0.724 et 0.549, suggérant que CPE pourrait ne pas être essentiel pour l'apprentissage. En contraste, LSSVM4, qui exclut certaines données piézométriques (PZ9) tout en conservant CPE, enregistre des améliorations de performance significatives, avec un R de 0.911, un NSE de 0.826, un RMSE de 0.646 et un MAE de 0.487. Les LSSVM5 à LSSVM8, en réduisant progressivement les données piézométriques, montrent une tendance constante à l'amélioration des performances, le LSSVM7 étant le meilleur avec les valeurs les plus élevées de R (0.937) et de NSE (0.875), ainsi que les taux d'erreur les plus bas, RMSE (0.548) et MAE (0.400). Cependant, les LSSVM9 à LSSVM12, en réduisant encore davantage les données piézométriques, montrent une baisse de performance, ce qui met en évidence un seuil potentiel pour l'utilisation de données piézométriques.

Dans la phase de validation qui a suivi, plusieurs modèles ont été évalués. Le LSSVM1, qui dispose d'un large éventail d'entrées, a atteint un R de 0.867 et un NSE de 0.743. Cependant, ses métriques d'erreur, avec un RMSE de 0.876 et un MAE de 0.727, suggèrent des possibilités d'amélioration. Le LSSVM2, qui ne contient pas de variables de calendrier grégorien, suit de près le LSSVM1 avec un R de 0.857 et un NSE de 0.730, mais présente des valeurs RMSE et MAE de 0.900 et 0.725, respectivement. Le LSSVM3, sans la variable CPE, affiche un R de 0.864, un NSE de 0.746, ainsi que des chiffres d'erreur RMSE de 0.873 et MAE de 0.725. Cependant, le LSSVM4 montre une baisse de performance en excluant une des entrées piézométriques (PZ9). Parmi les modèles de LSSVM5 à LSSVM8, le LSSVM7 se distingue par ses performances impressionnantes avec des valeurs élevées pour R (0.860), NSE (0.736), et des erreurs relativement faibles avec un RMSE de 0.889 et un MAE de 0.701. La dernière série de modèles, de LSSVM9 à LSSVM12, met en évidence les inconvénients de la réduction excessive des données piézométriques, avec LSSVM11 et LSSVM12 obtenant des résultats inférieurs en termes de performance. L'importance du CPE semble être contextuelle, dépendant des variables piézométriques associées. Parmi tous les modèles, le LSSVM7, qui combine les données de date, les données piézométriques sélectionnées et le CPE, se démarque comme le meilleur performeur lors de la phase de validation. En ce qui concerne l'évaluation des

performances de l'approche MARS, nous avons observé différentes tendances au cours de la phase d'apprentissage. Le modèle MARS1, qui intègre un ensemble complet de variables, a obtenu un R de 0.824, un NSE de 0.678, un RMSE de 0.878 et un MAE de 0.672. Bien qu'il présente une corrélation notable, sa capacité prédictive est modérée. MARS2, en excluant les variables temporelles, affiche un R de 0.856, un NSE de 0.733, un RMSE de 0.799 et un MAE de 0.627, suggérant une amélioration de l'efficacité sans ces variables. MARS3, en supprimant le CPE, surpasse les autres avec un R de 0.867, un NSE de 0.752, un RMSE de 0.771 et un MAE de 0.588.

**Tableau VII. 3.** Performances des différents modèles Neuroflous & barrage Zit Emba.

| Models   | Training |       |       |       | Validation |       |       |       |
|----------|----------|-------|-------|-------|------------|-------|-------|-------|
|          | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE  | MAE   |
| LSSVM1   | 0.836    | 0.686 | 0.867 | 0.655 | 0.867      | 0.743 | 0.876 | 0.727 |
| LSSVM2   | 0.828    | 0.684 | 0.870 | 0.639 | 0.857      | 0.730 | 0.900 | 0.725 |
| LSSVM3   | 0.885    | 0.781 | 0.724 | 0.549 | 0.864      | 0.746 | 0.873 | 0.725 |
| LSSVM4   | 0.911    | 0.826 | 0.646 | 0.487 | 0.854      | 0.728 | 0.903 | 0.727 |
| LSSVM5   | 0.905    | 0.815 | 0.666 | 0.501 | 0.852      | 0.725 | 0.906 | 0.730 |
| LSSVM6   | 0.902    | 0.809 | 0.676 | 0.507 | 0.849      | 0.721 | 0.915 | 0.734 |
| LSSVM7   | 0.937    | 0.875 | 0.548 | 0.400 | 0.860      | 0.736 | 0.889 | 0.701 |
| LSSVM8   | 0.931    | 0.864 | 0.570 | 0.414 | 0.857      | 0.731 | 0.898 | 0.711 |
| LSSVM9   | 0.921    | 0.846 | 0.608 | 0.440 | 0.855      | 0.726 | 0.906 | 0.722 |
| LSSVM10  | 0.901    | 0.809 | 0.677 | 0.489 | 0.845      | 0.709 | 0.932 | 0.748 |
| LSSVM11  | 0.861    | 0.739 | 0.790 | 0.575 | 0.838      | 0.700 | 0.948 | 0.755 |
| LSSVM12  | 0.820    | 0.671 | 0.888 | 0.648 | 0.846      | 0.716 | 0.922 | 0.741 |
| MARS1    | 0.824    | 0.678 | 0.878 | 0.672 | 0.858      | 0.731 | 0.898 | 0.730 |
| MARS2    | 0.856    | 0.733 | 0.799 | 0.627 | 0.855      | 0.705 | 0.939 | 0.791 |
| MARS3    | 0.867    | 0.752 | 0.771 | 0.588 | 0.851      | 0.723 | 0.911 | 0.751 |
| MARS4    | 0.801    | 0.642 | 0.926 | 0.688 | 0.861      | 0.735 | 0.891 | 0.724 |
| MARS5    | 0.798    | 0.637 | 0.933 | 0.695 | 0.856      | 0.724 | 0.909 | 0.735 |
| MARS6    | 0.801    | 0.642 | 0.926 | 0.688 | 0.861      | 0.735 | 0.891 | 0.724 |
| MARS7    | 0.801    | 0.642 | 0.926 | 0.688 | 0.861      | 0.735 | 0.891 | 0.724 |
| MARS8    | 0.801    | 0.642 | 0.926 | 0.688 | 0.861      | 0.735 | 0.891 | 0.724 |
| MARS9    | 0.798    | 0.637 | 0.933 | 0.696 | 0.856      | 0.724 | 0.909 | 0.735 |
| MARS10   | 0.776    | 0.603 | 0.975 | 0.743 | 0.852      | 0.712 | 0.929 | 0.785 |
| MARS11   | 0.782    | 0.612 | 0.964 | 0.725 | 0.864      | 0.717 | 0.920 | 0.782 |
| MARS12   | 0.782    | 0.612 | 0.964 | 0.725 | 0.864      | 0.717 | 0.920 | 0.782 |
| M5Tree1  | 0.868    | 0.749 | 0.775 | 0.588 | 0.865      | 0.688 | 0.966 | 0.758 |
| M5Tree2  | 0.872    | 0.755 | 0.765 | 0.565 | 0.833      | 0.675 | 0.987 | 0.800 |
| M5Tree3  | 0.865    | 0.743 | 0.784 | 0.584 | 0.854      | 0.688 | 0.967 | 0.735 |
| M5Tree4  | 0.873    | 0.759 | 0.759 | 0.579 | 0.860      | 0.681 | 0.977 | 0.776 |
| M5Tree5  | 0.867    | 0.750 | 0.773 | 0.585 | 0.856      | 0.678 | 0.981 | 0.763 |
| M5Tree6  | 0.869    | 0.754 | 0.767 | 0.583 | 0.857      | 0.673 | 0.990 | 0.775 |
| M5Tree7  | 0.858    | 0.735 | 0.797 | 0.572 | 0.859      | 0.669 | 0.996 | 0.816 |
| M5Tree8  | 0.874    | 0.763 | 0.754 | 0.558 | 0.866      | 0.702 | 0.944 | 0.758 |
| M5Tree9  | 0.857    | 0.730 | 0.803 | 0.556 | 0.857      | 0.692 | 0.960 | 0.785 |
| M5Tree10 | 0.882    | 0.773 | 0.737 | 0.539 | 0.876      | 0.735 | 0.891 | 0.775 |
| M5Tree11 | 0.886    | 0.777 | 0.731 | 0.533 | 0.884      | 0.742 | 0.880 | 0.759 |
| M5Tree12 | 0.872    | 0.753 | 0.768 | 0.565 | 0.879      | 0.738 | 0.886 | 0.759 |

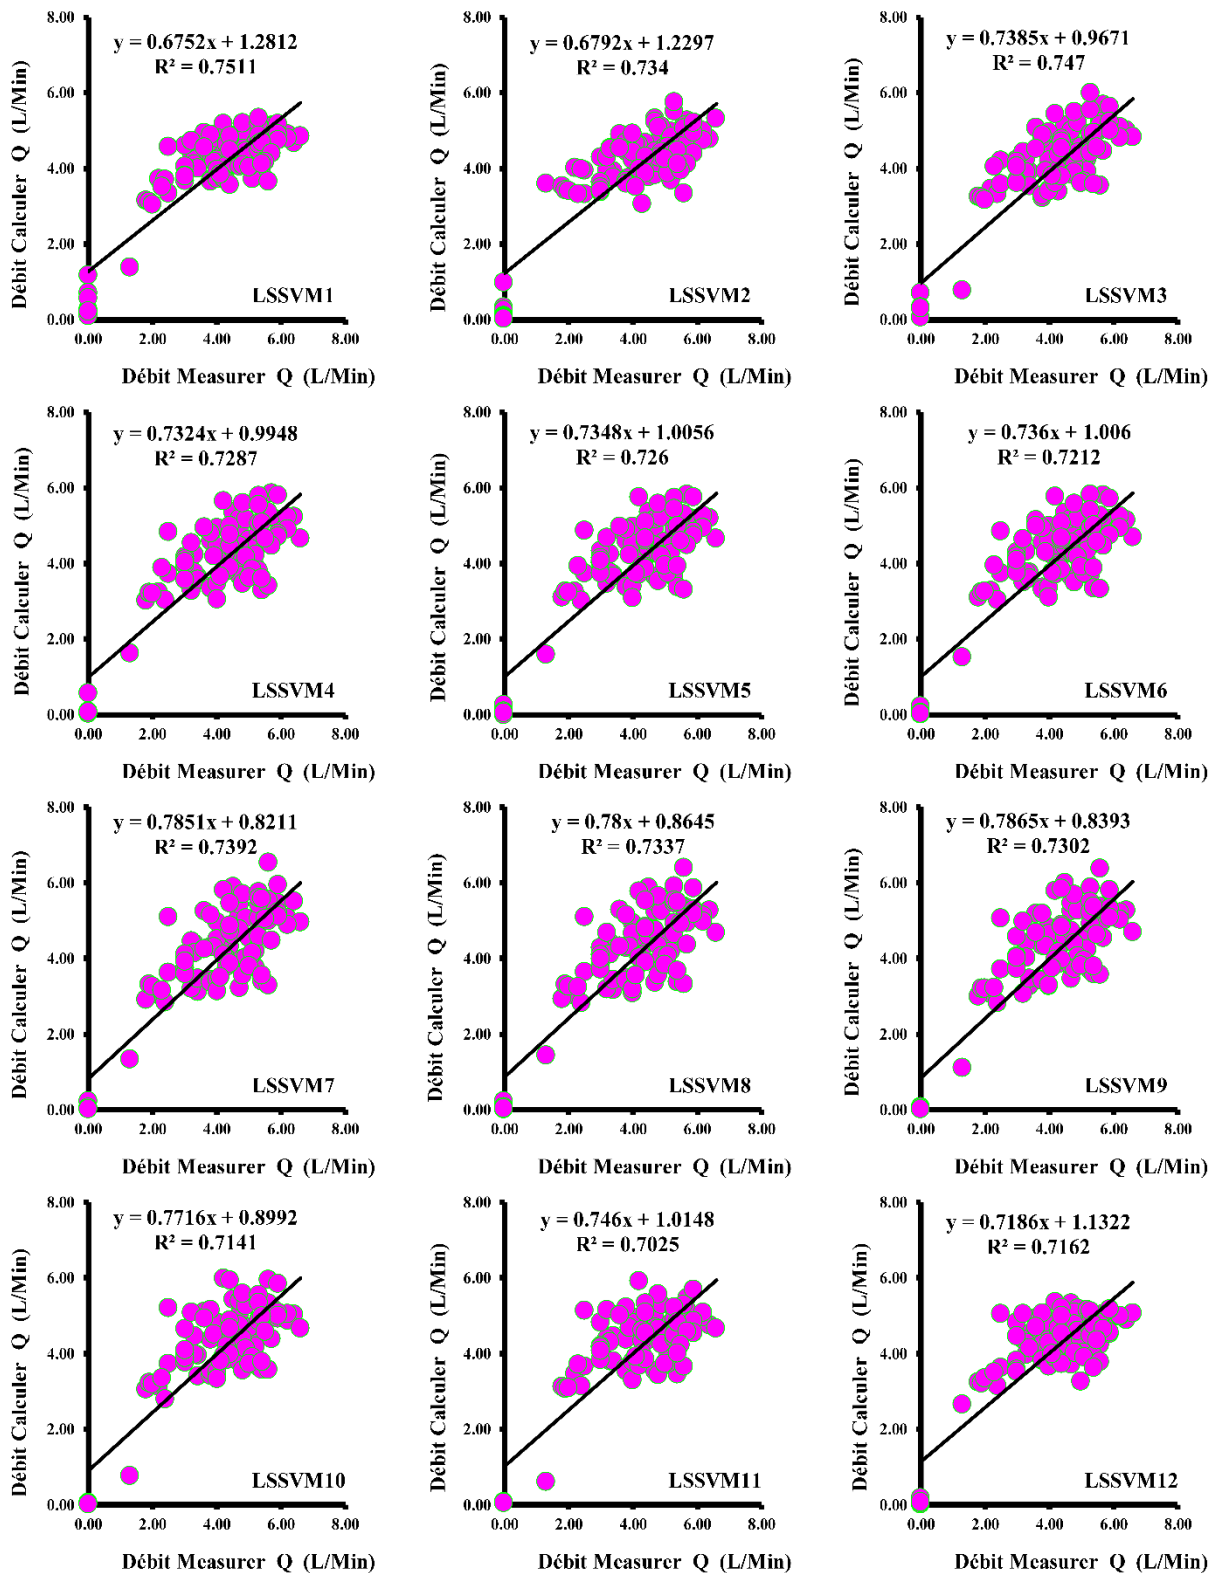


Figure VII. 11. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles LSSVM: barrage Zit Emba & phase de validation.

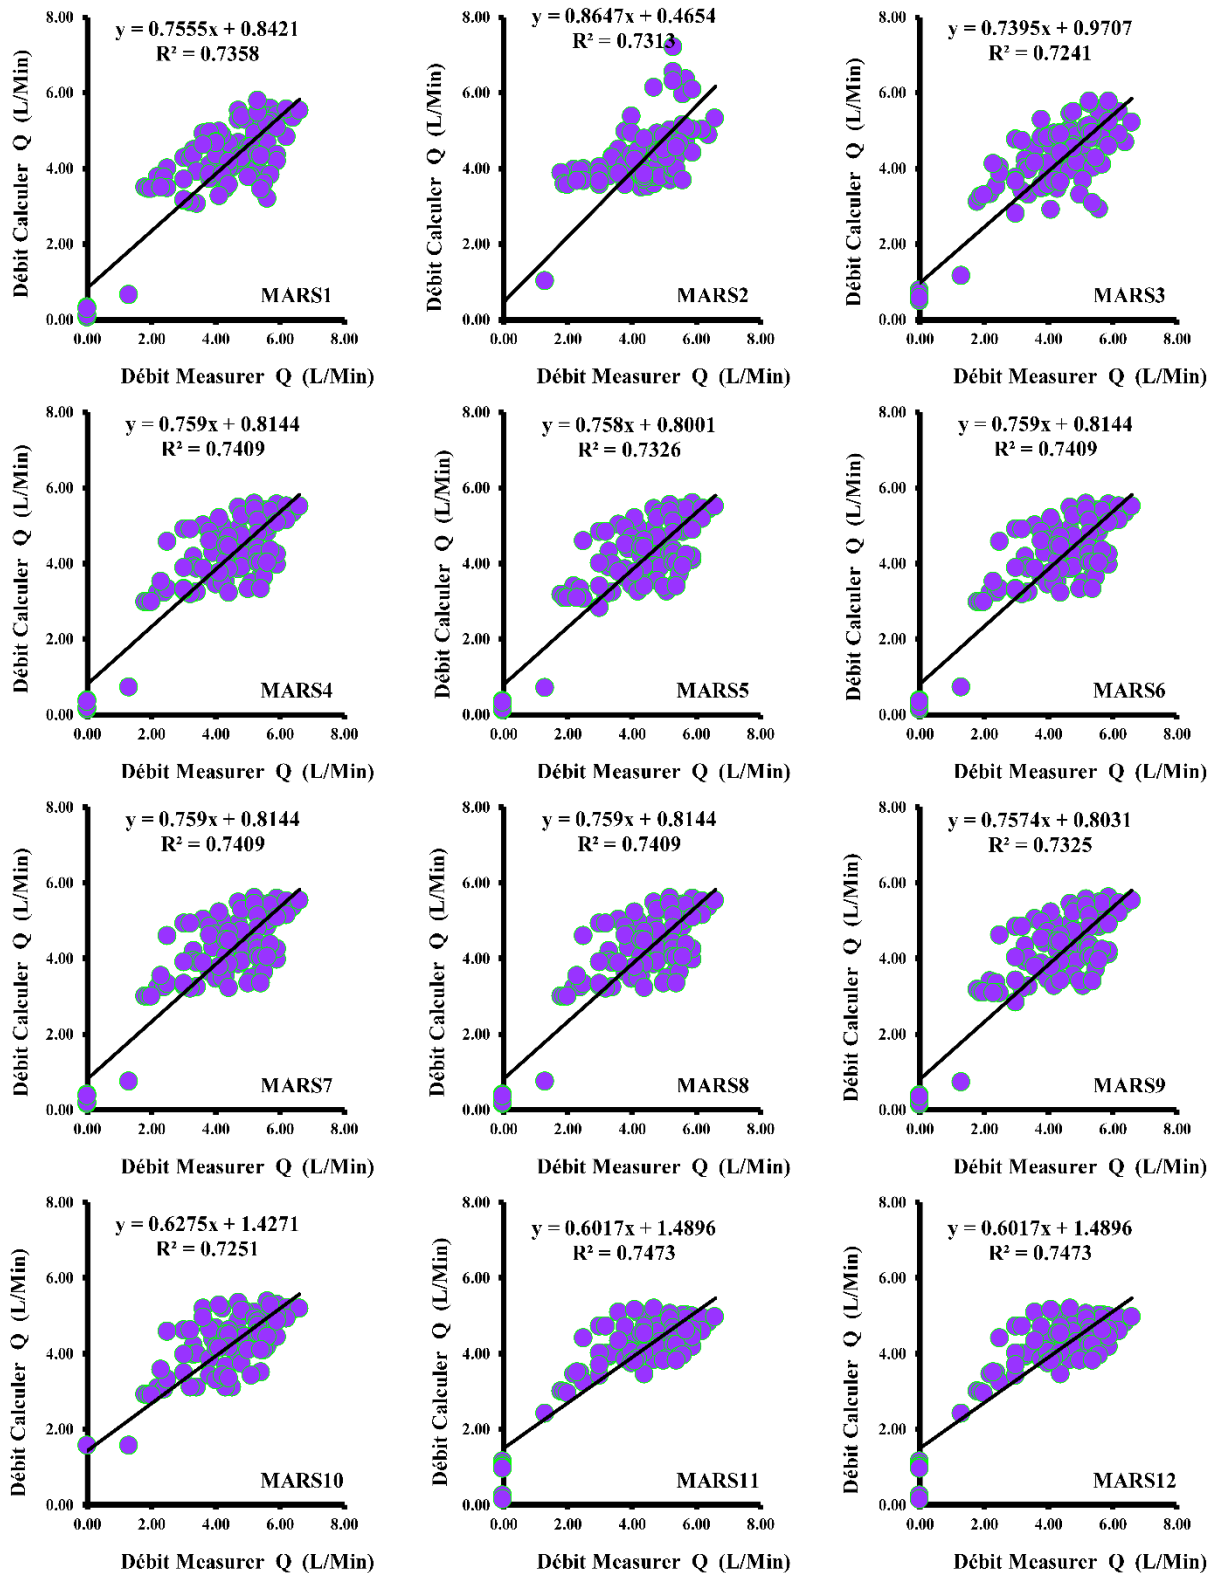


Figure VII. 12. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles MARS: barrage Zit Emba & phase de validation.

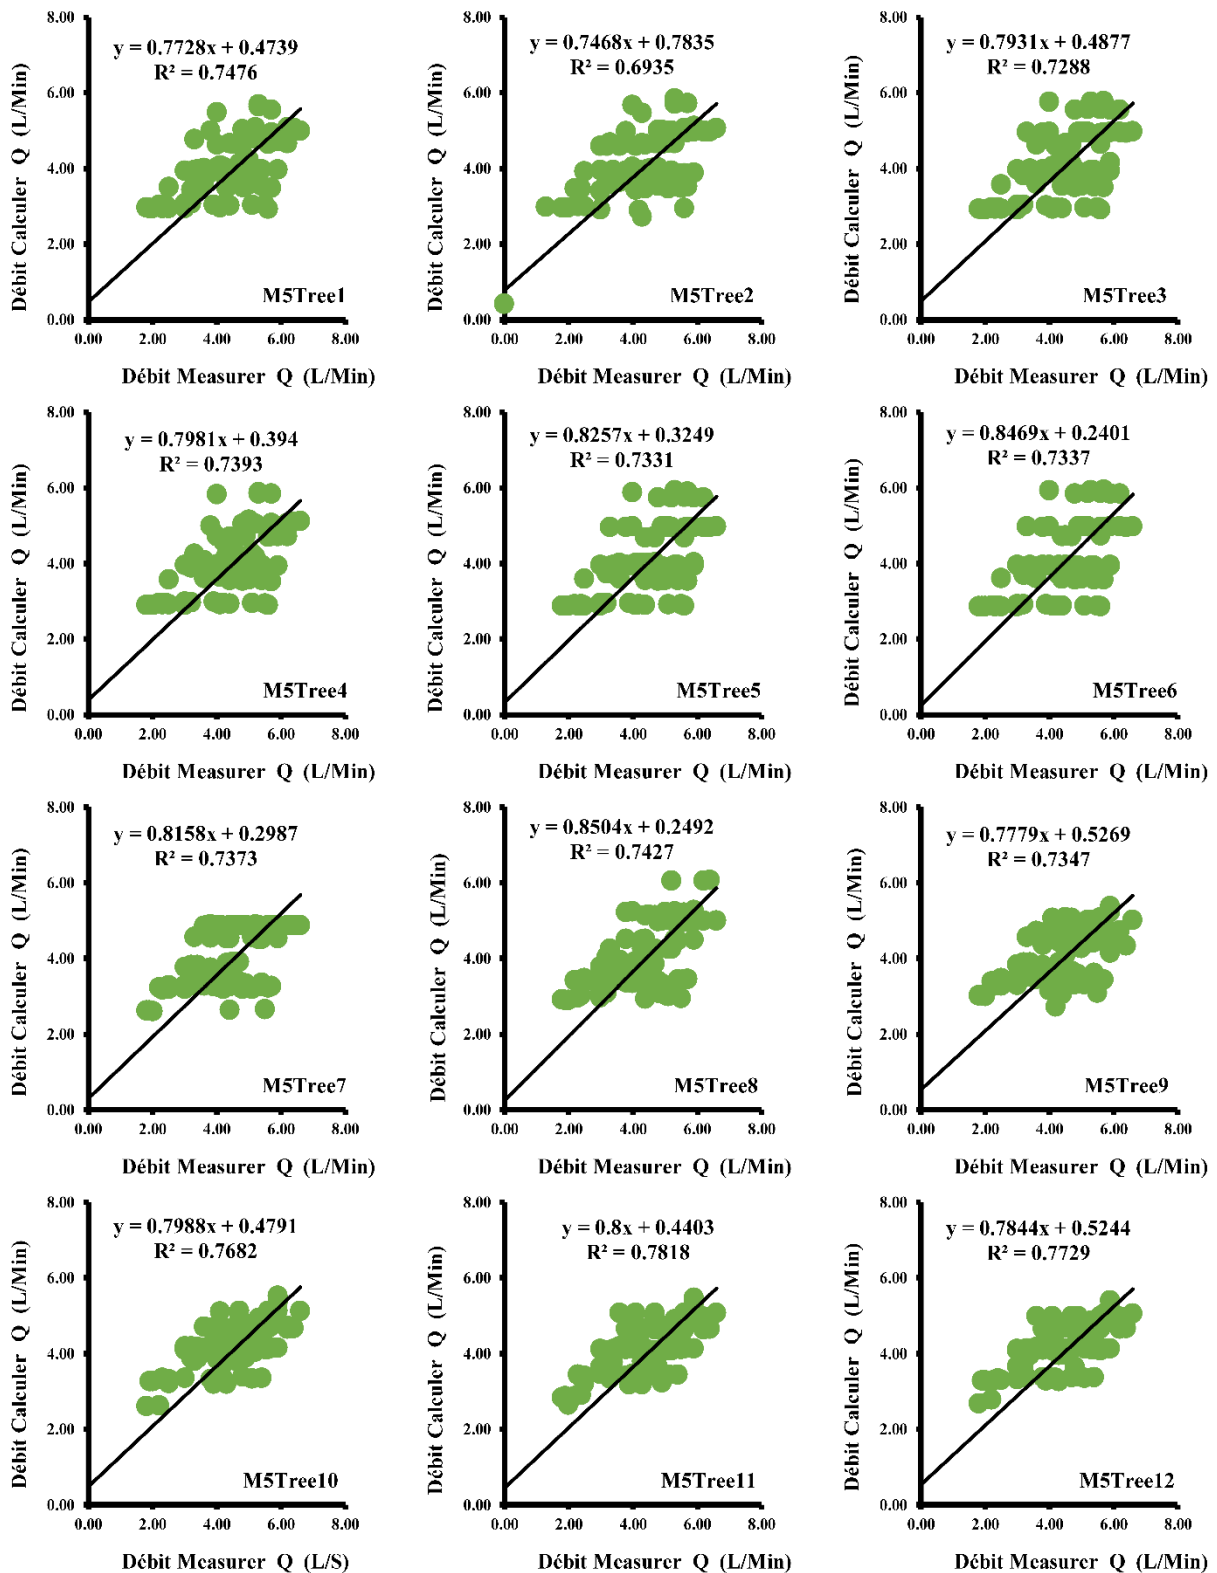


Figure VII. 13. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles M5Tree: barrage Zit Emba & phase de validation.

Cependant, MARS4, après la suppression de PZ9, montre une baisse de performance significative, avec un R de 0.801, un NSE de 0.642, un RMSE de 0.926 et un MAE de 0.688, soulignant ainsi l'importance des données piézométriques étendues. MARS5 à MARS8, malgré l'exclusion progressive des données piézométriques, maintiennent des performances similaires à MARS4. MARS9, avec un R de 0.798, un NSE de 0.637, un RMSE de 0.933 et un MAE de 0.696, montre une légère baisse, confirmant ainsi le rôle crucial de certaines données piézométriques. Enfin, MARS10 à MARS12, en simplifiant davantage les entrées, reflètent un déclin des performances avec un R d'environ 0.780, un NSE autour de 0.610, un RMSE près de 0.970 et un MAE proche de 0,730. En conclusion, MARS3 se démarque comme le modèle le plus efficace au cours de cette phase, tandis que MARS10 affiche des performances inférieures.

En Phase de Validation, le modèle MARS1 affiche des performances robustes avec un R de 0.858, un NSE de 0.731, un RMSE de 0.898 et un MAE de 0.730, malgré l'inclusion d'une gamme de variables en entrée. Cela suggère que la complexité de MARS1 ne nuit pas à sa capacité prédictive. En revanche, le modèle MARS2 montre un léger déclin du NSE à 0.705 par rapport à MARS1, bien que le R reste équivalent à 0.855. Cela suggère que les paramètres temporels supplémentaires inclus dans MARS1 peuvent contribuer à son efficacité en validation. MARS3 maintient une performance robuste avec un R de 0.851, un NSE de 0.723, un RMSE de 0.911 et un MAE de 0.751. La baisse de performance par rapport à la phase d'apprentissage suggère un éventuel surajustement lors de l'apprentissage. Les modèles MARS4, MARS6, MARS7 et MARS8 se situent dans une bande de performance similaire, avec des valeurs de R autour de 0.861, un NSE autour de 0.735, un RMSE autour de 0.891 et un MAE autour de 0.724. Leurs NSE relativement plus élevés et leurs erreurs plus faibles suggèrent qu'ils sont des modèles solides pour la phase de validation. MARS5 et MARS9 affichent des performances presque identiques, suggérant que l'ajout de données piézométriques au-delà de PZ3 ne semble pas améliorer significativement les performances en validation. En revanche, les modèles MARS10 à MARS12 continuent de montrer une tendance à la baisse des performances, bien que des valeurs de R autour de 0.864, mais des NSE plus bas (autour de 0.717) et des erreurs plus élevées (RMSE autour de 0.920 et MAE autour de 0.782). Le modèle le plus performant pendant la phase de validation semble être MARS4, car il présente un NSE et un R élevés tout en maintenant les métriques d'erreur les plus basses. En revanche, le modèle le moins performant pendant cette phase semble être MARS12, qui affiche le NSE le plus bas et les métriques d'erreur les plus élevées. Une analyse plus approfondie révèle l'impact majeur des données piézométriques sur les performances des modèles. Il est intéressant de noter que la simplification des données d'entrée n'entraîne pas systématiquement une baisse de la performance, ce qui ouvre des perspectives d'optimisation par le biais de la sélection d'entrées. Cependant, les baisses de performance observées pour MARS10-12 soulignent une fois de plus l'importance cruciale des données piézométriques dans la modélisation précise du barrage de Zit Emba.

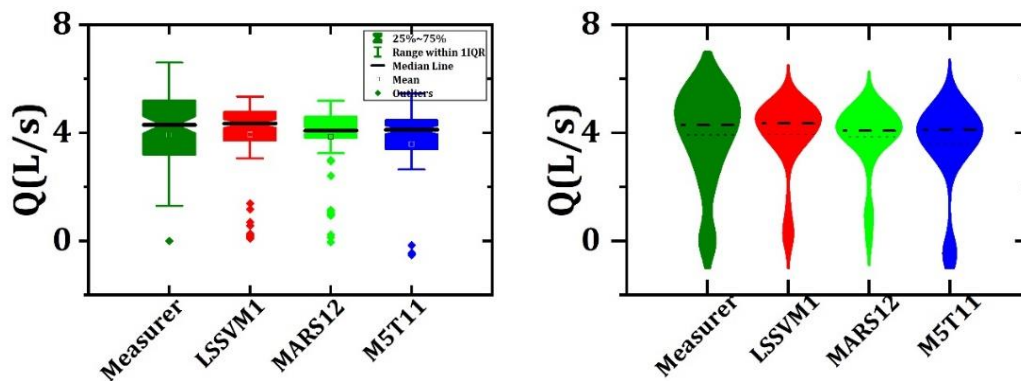
L'efficacité des différents M5Tree modèles a été évaluée sur la base du jeu de données fourni. Le modèle M5Tree1, présentant un R de 0.868 et un NSE de 0.749, indiquait une corrélation linéaire positive avec le débit de fuite observé. Néanmoins, ses erreurs modérées étaient respectivement de 0.775 L/Min (RMSE) et 0.588 L/Min (MAE). Le modèle M5Tree2, avec des métriques de corrélation améliorées (R=0.872, NSE=0.755) et des erreurs similaires à M5Tree1, suggérait une performance prédictive indépendante du temps. Le M5Tree3, présentant un R de 0.865 et un NSE de 0.743, ainsi que des erreurs proches de ses prédécesseurs,

indiquait que les variables de date sans le niveau d'eau (CPE) n'influençaient pas significativement les erreurs prédictives. M5Tree4, après avoir exclu les données piézométriques PZ9, a affiché une amélioration relative avec un R de 0.873 et des erreurs réduites (RMSE=0.759 L/Min, MAE=0.579 L/Min) par rapport au modèle M5Tree1. Ceci suggère que l'inclusion de toutes les données piézométriques n'a pas nécessairement un impact positif sur les performances du modèle. M5Tree5 et M5Tree6 ont démontré une performance stable malgré une réduction des variables piézométriques. Cependant, M5Tree7 a affiché une légère baisse en performance, notamment un R de 0.858 et des erreurs plus importantes. En contraste, M5Tree8, avec le NSE le plus élevé de 0.763, soulignait l'importance d'une sélection judicieuse des données piézométriques. Bien que M5Tree9 présente une performance moindre, M5Tree10 et M5Tree11 ont mis en évidence l'efficacité d'une sélection optimale des données piézométriques associées aux variables de date et au CPE. Enfin, M5Tree12, centré uniquement sur les variables de date et le CPE, a confirmé l'importance de l'intégration des données piézométriques appropriées pour une prédiction améliorée, en dépit d'une performance notable (R=0.872) mais avec des erreurs de 0.769 L/Min (RMSE) et 0.555 L/Min (MAE)


Pendant la phase de validation, qui vise à évaluer l'efficacité des modèles sur des données inédites, M5Tree1 a enregistré un R de 0.865, un NSE de 0.688, mais des erreurs considérables de 0.966 L/Min (RMSE) et 0.758 L/Min (MAE), mettant en évidence des lacunes en termes de précision. En comparaison, M5Tree2 a montré une légère régression de performance avec R=0.833, NSE=0.675 et des erreurs de 0.987L/Min (RMSE) et 0.800 L/Min (MAE). M5Tree3 et M5Tree4 ont affiché une performance cohérente, suggérant une robustesse du modèle. Tandis que M5Tree3 a présenté un R de 0.854, un NSE de 0.688, et des erreurs de 0.967 L/Min et 0.735 L/Min, M5Tree4 a légèrement progressé avec un R de 0.860, mais des erreurs similaires. M5Tree5 à M5Tree7, avec des valeurs de R entre 0.856 et 0.859 et un NSE de 0.669 à 0.678, ont vu leurs erreurs augmenter, M5Tree7 atteignant un RMSE de 0.996 L/Min et un MAE de 0.816 L/Min. Cela indique une concession en termes de précision avec une réduction des données piézométriques. M5Tree8 a surpassé les autres avec un R de 0.866, un NSE de 0.702, suggérant une meilleure sélection des données piézométriques. Toutefois, M5Tree9 a montré une diminution de ses performances. M5Tree10 et M5Tree11 se sont démarqués, en particulier M5Tree11 avec R=0.884, NSE=0.742, et des erreurs de 0.880 L/Min et 0.759 L/Min. M5Tree12 a confirmé l'importance de privilégier la qualité des entrées plutôt que leur quantité. En résumé, M5Tree11, grâce à une sélection minutieuse des données en entrée, a dominé, tandis que M5Tree2 a montré des signes de surajustement. Ces résultats mettent en lumière l'importance cruciale d'une sélection appropriée des variables pour optimiser les modèles basés sur l'IA.

- I) Au cours des phases d'apprentissage et de validation, le modèle LSSVM, en particulier LSSVM7, a constamment surpassé les modèles MARS et M5Tree, affichant des valeurs élevées pour les coefficients R et NSE. Ces métriques témoignent d'une relation linéaire marquée entre les valeurs observées et prédites, ce qui reflète la supériorité de LSSVM7 en termes de prédiction. Il convient de noter que les valeurs réduites de RMSE et de MAE de LSSVM7 mettent en évidence sa précision exceptionnelle, tandis que le modèle MARS montre une variabilité, suggérant une sensibilité à différentes configurations d'entrée. En revanche, les valeurs favorables de RMSE et de MAE de M5Tree lors de la validation soulignent sa capacité à extrapoler efficacement sur des ensembles de données inconnus.

- 2) Les modèles utilisant des ensembles complets de paramètres en entrée, tels que les données de date, les données piézométriques, et le niveau d'eau du réservoir comme illustré par le Modèle M1 démontrent généralement de meilleures performances, en particulier dans le contexte du LSSVM. Plus précisément, le modèle LSSVM1 a affiché une valeur remarquable de R en validation, atteignant 0.867, ce qui témoigne de sa capacité prédictive puissante. Ces résultats renforcent l'idée que l'intégration d'un éventail plus large de variables pertinentes permet de capturer de manière plus efficace les relations inhérentes aux données.
- 3) En analysant le rôle des paramètres temporels, des modèles tels que M2, qui omettent les informations de date tout en conservant les autres variables, montrent des performances légèrement inférieures ou comparables à celles des modèles comme M1. Cette tendance est particulièrement évidente dans le cas des variantes LSSVM. Par exemple, la comparaison entre le LSSVM1 (intégrant la date) et le LSSVM2 (excluant la date) révèle une légère diminution de la valeur du coefficient NSE en validation, passant de 0.735 à 0.704. Cette nuance suggère que bien que les paramètres de date apportent une certaine valeur, leur absence peut être compensée par l'influence d'autres facteurs cruciaux dans la prédiction du débit des fuites.
- 4) En passant de M1 à M12, il y a une réduction du nombre de points de données piézométriques (P1 à P9), corrélant avec une performance du modèle généralement diminuée. Cette dégradation est particulièrement évidente dans le LSSVM, où le LSSVM11 manifeste l'une des valeurs NSE inférieures associées à des métriques RMSE & MAE élevées, soulignant l'indispensabilité des données piézométriques dans la modélisation de précision du débit des fuites.
- 5) Finalement une comparaison entre les meilleurs modèles en termes graphiques est présentée dans les deux figures VII.14 et VII.15.



**Figure VII. 14.** Comparaison entre les différents modèles Ensemblistes par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Zit Emba.



**Figure VII. 15.** Le diagramme de Taylor pour la comparaison entre les meilleurs modèles Ensemblistes: Barrage Zit Emba.

## VII.6. Résultats Obtenus par les Modèles Ensemblistes: Barrage Foum El Khanga

Les résultats obtenus au niveau du barrage Foum El Khanga sont reportés dans le **Tableau VI.4**. La comparaison entre les valeurs mesurées et calculées par les différents modèles est représentée en termes de Scatterplot dans les **Figures VII.16-18**. En phase d'apprentissage, les résultats ont démontré que LSSVM1, qui intègre des données calendaires, piézométriques et le niveau d'eau (CPE), a présenté une performance médiane avec les indicateurs suivants :  $R=0.849$ ,  $NSE=0.695$ ,  $RMSE=0.094$  et  $MAE=0.066$ . En revanche, le LSSVM2, qui exclut les données calendaires tout en conservant les mesures piézométriques et le CPE, s'est distingué par sa précision supérieure avec les valeurs suivantes  $R=0.929$ ,  $NSE=0.850$ ,  $RMSE=0.066$  et  $MAE=0.036$ . Ces résultats mettent en évidence l'importance prépondérante des mesures piézométriques et du niveau d'eau dans la prédiction, minimisant ainsi l'impact des données calendaires. À l'opposé, LSSVM3, qui inclut les données calendaires tout en excluant le CPE, a affiché une précision moindre avec les indicateurs suivants :  $R=0.802$ ,  $NSE=0.623$ ,  $RMSE=0.105$  et  $MAE=0.073$ . Finalement, le LSSVM4, bien que combinant le CPE, les données calendaires et les mesures piézométriques (sauf P9), a montré des résultats analogues à LSSVM3. Les modèles LSSVM5 à LSSVM8 ont progressivement exclu certaines mesures piézométriques tout en conservant les données calendaires et le CPE. Leurs métriques de performance ont révélé une légère variation, principalement dans les intervalles de  $R$  (0.801 à 0.825),  $NSE$  (0.620 à 0.661),  $RMSE$  (0.099 à 0.105) et  $MAE$  (0.068 à 0.075). Cela illustre l'effet non drastique de l'omission de points piézométriques spécifiques, mais aucun modèle de cette série n'a atteint l'efficacité de LSSVM2. Les modèles suivants, LSSVM9 à LSSVM12, ont encore réduit les entrées piézométriques tout en conservant les données calendaires et le CPE. Ces modèles ont enregistré une baisse constante des performances, avec des métriques telles que les valeurs  $R$  comprises entre 0.763 et 0.793, et des  $NSE$  allant de 0.577 à 0.614, mettant en évidence le rôle crucial des données piézométriques dans la précision. En somme, l'efficacité prédictive est grandement influencée par la disponibilité des données piézométriques. Bien que les données calendaires jouent un rôle, elles ont une influence moins déterminante dans la prédiction du débit de fuite, comme illustré par la comparaison entre LSSVM1 et LSSVM2.

**Tableau VII. 4.** Performances des différents modèles Neuroflous & barrage Foug El Khanga.

| Models   | Training |       |       |       | Validation |       |       |       |
|----------|----------|-------|-------|-------|------------|-------|-------|-------|
|          | R        | NSE   | RMSE  | MAE   | R          | NSE   | RMSE  | MAE   |
| LSSVM1   | 0.849    | 0.695 | 0.094 | 0.066 | 0.613      | 0.375 | 0.148 | 0.113 |
| LSSVM2   | 0.929    | 0.850 | 0.066 | 0.036 | 0.710      | 0.503 | 0.132 | 0.091 |
| LSSVM3   | 0.802    | 0.623 | 0.105 | 0.073 | 0.565      | 0.318 | 0.155 | 0.118 |
| LSSVM4   | 0.790    | 0.603 | 0.107 | 0.077 | 0.605      | 0.366 | 0.149 | 0.116 |
| LSSVM5   | 0.801    | 0.620 | 0.105 | 0.075 | 0.590      | 0.347 | 0.152 | 0.118 |
| LSSVM6   | 0.787    | 0.601 | 0.107 | 0.077 | 0.583      | 0.338 | 0.153 | 0.119 |
| LSSVM7   | 0.825    | 0.661 | 0.099 | 0.068 | 0.591      | 0.348 | 0.151 | 0.115 |
| LSSVM8   | 0.815    | 0.646 | 0.101 | 0.070 | 0.598      | 0.357 | 0.150 | 0.114 |
| LSSVM9   | 0.793    | 0.614 | 0.106 | 0.075 | 0.605      | 0.364 | 0.150 | 0.114 |
| LSSVM10  | 0.768    | 0.583 | 0.110 | 0.078 | 0.587      | 0.338 | 0.153 | 0.115 |
| LSSVM11  | 0.763    | 0.577 | 0.111 | 0.079 | 0.645      | 0.416 | 0.143 | 0.110 |
| LSSVM12  | 0.782    | 0.608 | 0.107 | 0.076 | 0.602      | 0.357 | 0.150 | 0.119 |
| MARS1    | 0.787    | 0.620 | 0.105 | 0.075 | 0.641      | 0.395 | 0.146 | 0.117 |
| MARS2    | 0.856    | 0.732 | 0.088 | 0.057 | 0.786      | 0.354 | 0.151 | 0.105 |
| MARS3    | 0.614    | 0.377 | 0.134 | 0.105 | 0.538      | 0.205 | 0.167 | 0.128 |
| MARS4    | 0.688    | 0.473 | 0.124 | 0.086 | 0.662      | 0.425 | 0.142 | 0.107 |
| MARS5    | 0.751    | 0.564 | 0.112 | 0.076 | 0.598      | 0.321 | 0.155 | 0.099 |
| MARS6    | 0.618    | 0.382 | 0.134 | 0.105 | 0.578      | 0.318 | 0.155 | 0.120 |
| MARS7    | 0.618    | 0.382 | 0.134 | 0.105 | 0.578      | 0.318 | 0.155 | 0.120 |
| MARS8    | 0.618    | 0.382 | 0.134 | 0.105 | 0.578      | 0.318 | 0.155 | 0.120 |
| MARS9    | 0.618    | 0.382 | 0.134 | 0.105 | 0.578      | 0.318 | 0.155 | 0.120 |
| MARS10   | 0.618    | 0.382 | 0.134 | 0.105 | 0.578      | 0.318 | 0.155 | 0.120 |
| MARS11   | 0.618    | 0.382 | 0.134 | 0.105 | 0.578      | 0.318 | 0.155 | 0.120 |
| MARS12   | 0.618    | 0.382 | 0.134 | 0.105 | 0.578      | 0.318 | 0.155 | 0.120 |
| M5Tree1  | 0.791    | 0.598 | 0.108 | 0.079 | 0.665      | 0.441 | 0.140 | 0.102 |
| M5Tree2  | 0.813    | 0.584 | 0.110 | 0.083 | 0.736      | 0.510 | 0.131 | 0.102 |
| M5Tree3  | 0.748    | 0.522 | 0.118 | 0.092 | 0.474      | 0.207 | 0.167 | 0.135 |
| M5Tree4  | 0.817    | 0.643 | 0.102 | 0.075 | 0.671      | 0.447 | 0.140 | 0.100 |
| M5Tree5  | 0.860    | 0.740 | 0.087 | 0.058 | 0.744      | 0.541 | 0.127 | 0.087 |
| M5Tree6  | 0.860    | 0.740 | 0.087 | 0.058 | 0.744      | 0.541 | 0.127 | 0.087 |
| M5Tree7  | 0.860    | 0.740 | 0.087 | 0.058 | 0.744      | 0.541 | 0.127 | 0.087 |
| M5Tree8  | 0.860    | 0.740 | 0.087 | 0.058 | 0.744      | 0.541 | 0.127 | 0.087 |
| M5Tree9  | 0.860    | 0.740 | 0.087 | 0.058 | 0.744      | 0.541 | 0.127 | 0.087 |
| M5Tree10 | 0.860    | 0.740 | 0.087 | 0.058 | 0.744      | 0.541 | 0.127 | 0.087 |
| M5Tree11 | 0.860    | 0.740 | 0.087 | 0.058 | 0.744      | 0.541 | 0.127 | 0.087 |
| M5Tree12 | 0.860    | 0.740 | 0.087 | 0.058 | 0.744      | 0.541 | 0.127 | 0.087 |

Pendant la phase de validation, le modèle LSSVM1, utilisant des données calendaires grégoriennes, des mesures piézométriques et le niveau d'eau (CPE) comme entrées, a obtenu un coefficient de corrélation R de 0.613, une efficacité NSE de 0.375, une RMSE de 0.148 et une MAE de 0.113. Bien que cette configuration ait montré une corrélation modérée entre les débits de fuite observés et prédits, son efficacité semble quelque peu limitée en comparaison avec d'autres modèles. En revanche, LSSVM2, excluant les données calendaires tout en incluant toutes les mesures piézométriques et le CPE, a présenté un R de 0.710, un NSE de 0.503, un

RMSE de 0.132 et un MAE de 0.091. Conservant des performances plutôt acceptables de la phase d'apprentissage, ce modèle démontre sa cohérence et sa capacité à s'adapter aux nouvelles données. Le LSSVM3, intégrant les données calendaires grégoriennes et piézométriques mais dépourvu de CPE, a enregistré un R de 0.565, un NSE de 0.318, un RMSE de 0.155 et un MAE de 0.118. Sa performance, nettement inférieure à celle de LSSVM1, souligne le rôle crucial du CPE dans le modèle. LSSVM4, malgré des entrées similaires à LSSVM1, à l'exception des données piézométriques PZ9, a produit des résultats légèrement supérieurs à LSSVM3, sans toutefois égaler l'efficacité de LSSVM2. Les modèles LSSVM5 à LSSVM8, réduisant progressivement les mesures piézométriques tout en conservant les données calendaires grégoriennes et le CPE, ont affiché des valeurs de R principalement entre 0.590 et 0.598, avec des valeurs NSE, RMSE et MAE indiquant une baisse de performance cohérente mais pas sévère. Cette tendance confirme la valeur intrinsèque d'un ensemble de données piézométriques complet. Dans la série LSSVM9 à LSSVM12, avec des variables d'entrée encore plus simplifiées, les indicateurs de performance se situaient principalement entre des valeurs R de 0.587 à 0.645, NSE de 0.338 à 0.416, RMSE de 0.143 à 0.153 et MAE de 0.110 à 0.119. Étonnamment, des modèles comme LSSVM11 ont montré une efficacité améliorée par rapport à LSSVM5 à LSSVM8, suggérant les avantages des modèles simplifiés. En conclusion, LSSVM2 est resté prédominant lors de la validation, conservant ses indicateurs supérieurs de la phase d'apprentissage, mettant ainsi en relief sa robustesse pour les prédictions de débits de fuite. En contraste flagrant, LSSVM3, dénué de CPE, a affiché l'efficacité la plus faible, soulignant l'indispensabilité du CPE. Cette analyse approfondie suggère que la complexité d'un modèle ne détermine pas nécessairement sa performance lors de la validation. Ce constat met l'accent sur la nécessité d'une sélection judicieuse des caractéristiques pour éviter le surajustement, garantissant que les modèles traitent efficacement des données inconnues.

En phase d'apprentissage, des disparités notables dans les performances des modèles MARS ont été observées. MARS1, qui a intégré à la fois le calendrier grégorien et les données piézométriques avec le CPE, a obtenu un R de 0.787, un NSE de 0.620, un RMSE de 0.105, et un MAE de 0.075. Ces résultats indiquent un niveau satisfaisant de corrélation et d'efficacité du modèle. En revanche, MARS2, qui a omis les variables temporelles mais a conservé les données piézométriques et le CPE, a montré une meilleure performance avec des métriques de  $R=0.856$ ,  $NSE=0.732$ ,  $RMSE=0.088$ , et  $MAE=0.057$ . Ces résultats suggèrent que, dans cet ensemble de données d'apprentissage, les variables du calendrier grégorien pourraient être moins cruciales pour les prédictions. Cependant, MARS3, qui a réintroduit les variables temporelles mais a exclu le CPE, a connu une baisse de performance, avec  $R=0.614$ ,  $NSE=0.377$ ,  $RMSE=0.134$ , et  $MAE=0.105$ . Ce résultat souligne l'importance potentielle du CPE dans le processus de modélisation. MARS4, bien qu'ayant des entrées similaires à MARS1, à l'exception des données piézométriques PZ9, a obtenu de meilleurs résultats que MARS3, bien qu'il n'atteigne pas l'efficacité de MARS1 et MARS2, mettant ainsi en évidence l'importance des données piézométriques étendues. Cependant, après avoir supprimé PZ9 et PZ8, MARS4 a montré une amélioration significative des performances, avec un R de 0.801, un NSE de 0.642, un RMSE de 0.926, et un MAE de 0.688, se rapprochant ainsi des performances de MARS1. De manière intéressante, les modèles MARS6 à MARS12, malgré différentes combinaisons d'entrées, ont tous affiché des métriques semblables ( $R=0.618$ ,  $NSE=0.382$ ,  $RMSE=0.134$ , et  $MAE=0.105$ ). Ces résultats parmi ces modèles nécessitent un examen des éventuelles incohérences computationnelles ou des préoccupations de surapprentissage.

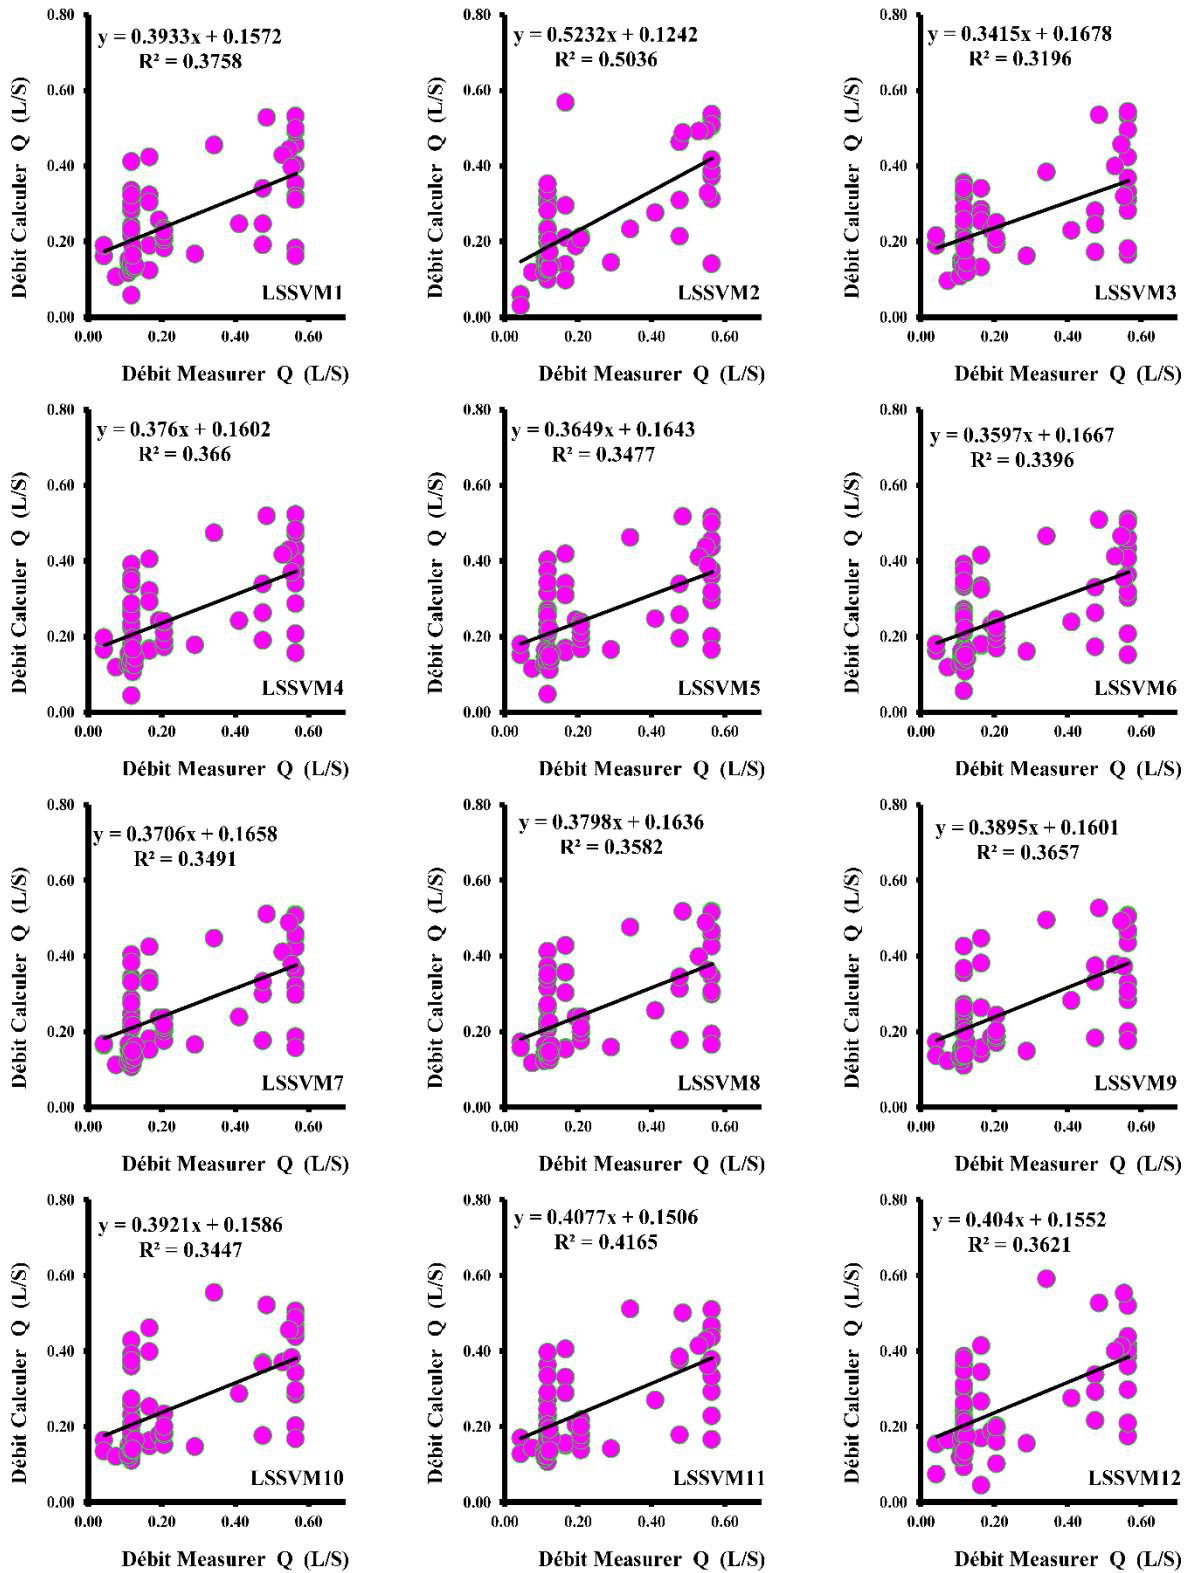


Figure VII. 16. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles LSSVM: barrage Foum El Khanga & phase de validation.

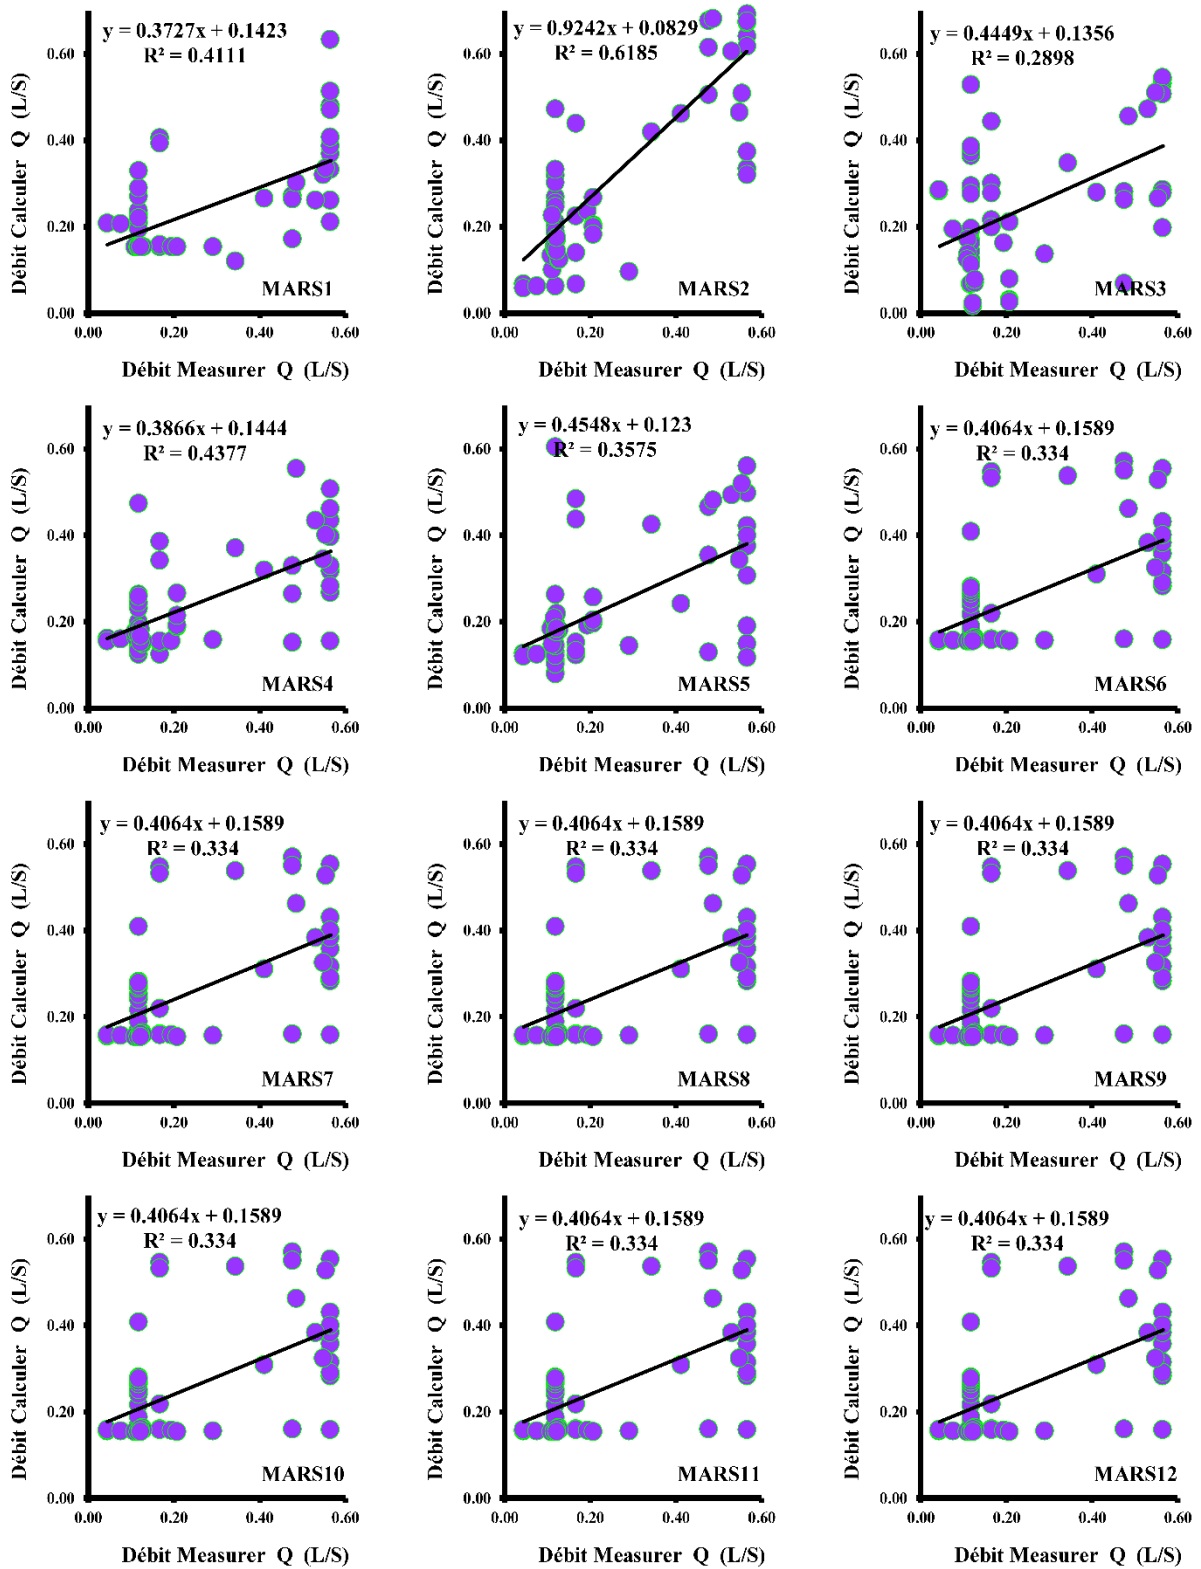
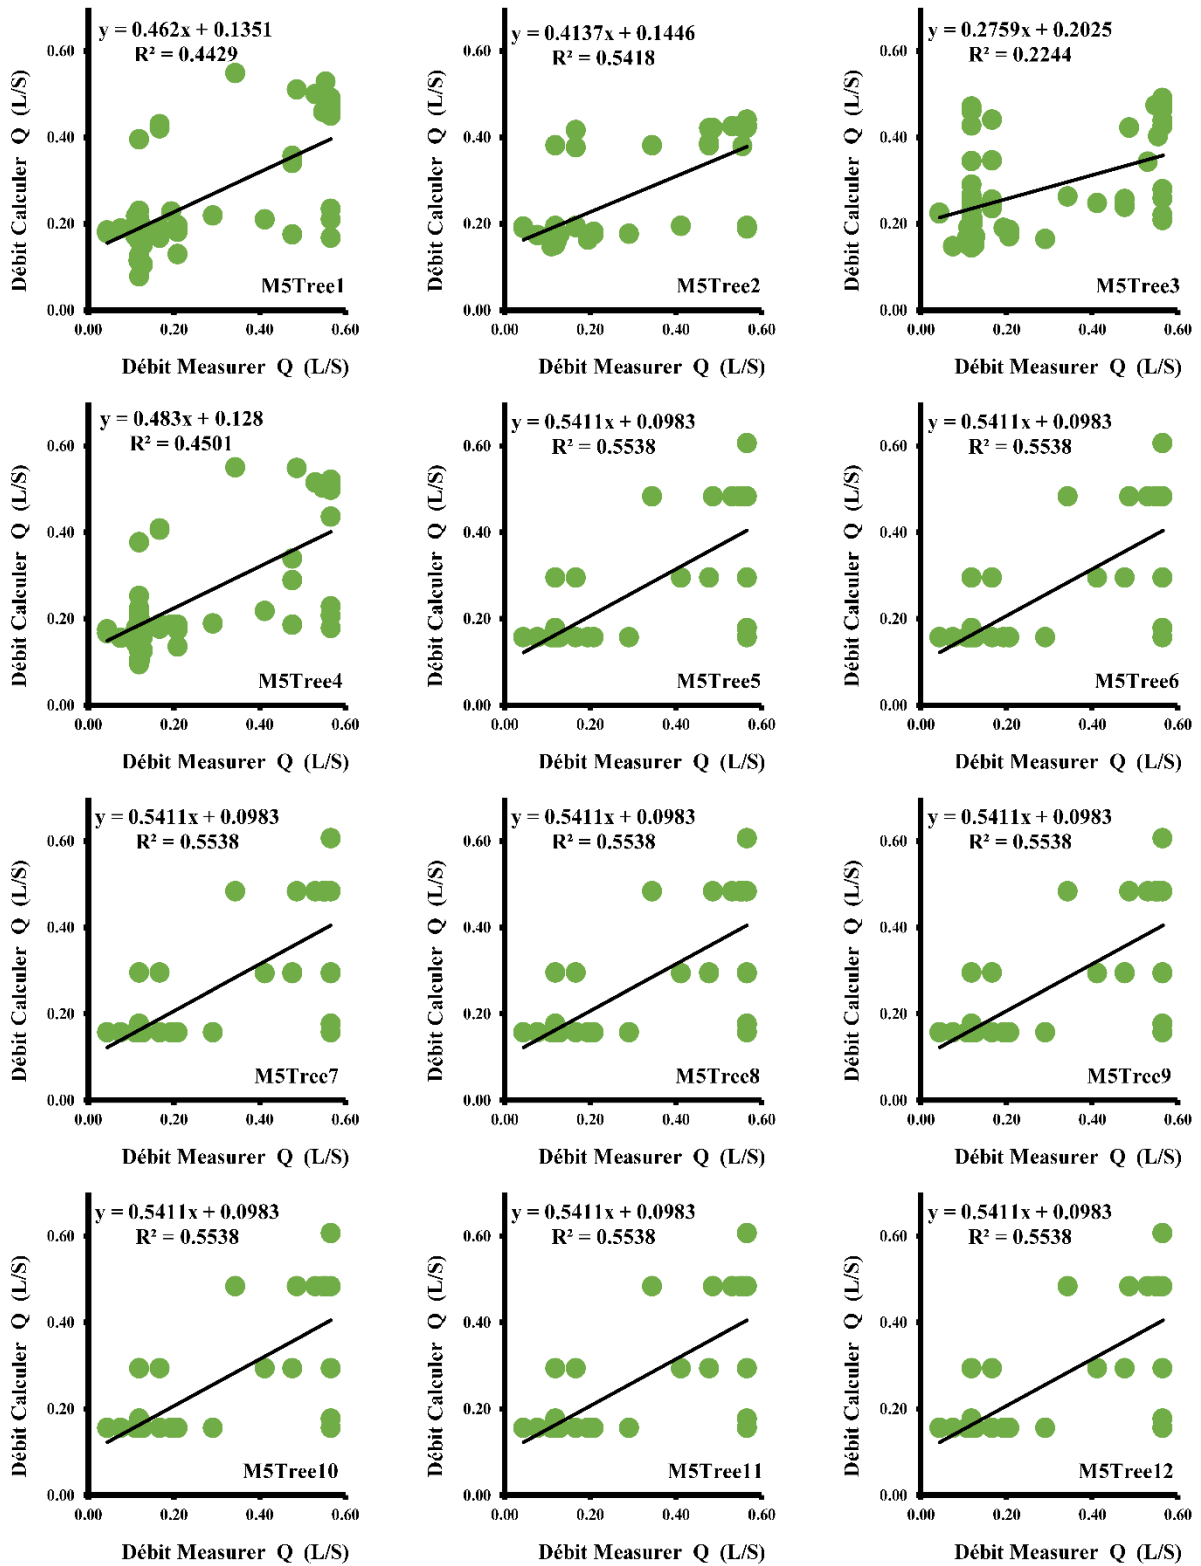


Figure VII. 17. Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles MARS: barrage Foug El Khanga & phase de validation.



**Figure VII. 18.** Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles M5Tree: barrage Foum El Khanga & phase de validation.

Lors de la transition vers la phase de validation, les performances du MARS1 pour l'ensemble de validation étaient raisonnables, mais non exceptionnelles, affichant un R de 0.641, un NSE de 0.395, une RMSE de 0.146, et une MAE de 0.117. Le MARS2 a maintenu sa performance solide, enregistrant un R de 0.786, un NSE de 0.354, un RMSE de 0.151, et un MAE de 0.105. Sa constance à travers les ensembles d'apprentissage et de validation met en évidence sa capacité de généralisation. En revanche, les métriques du MARS3 ont renforcé sa performance relativement plus faible, avec un R de 0.538, un NSE de 0.205, un RMSE de 0.167, et un MAE de 0.128. Le MARS4 a obtenu un R de 0.662, un NSE de 0.425, un RMSE de 0,142, et un MAE de 0,107, suggérant une performance constante avec une légère variance. Les résultats du MARS5 ont révélé un R de 0.598, un NSE de 0.321, un RMSE de 0.155, et un MAE de 0.099, indiquant un écart de prédiction légèrement plus important. Comme observé lors de la phase d'apprentissage, les modèles MARS4 à MARS12 ont à nouveau montré des métriques uniformes lors de la phase de validation, tous affichant un R de 0.578, un NSE de 0.318, un RMSE de 0.155, et un MAE de 0.120. La performance constante de ces modèles, indépendamment des variations des données d'entrée, soulève la nécessité d'une révision approfondie de l'architecture du modèle et de l'analyse des subtilités de l'ensemble de données. Dans la phase de validation, le MARS2 s'est révélé une fois de plus être le modèle supérieur, en particulier en ce qui concerne les valeurs de R et de MAE, tandis que le MARS3 a affiché les métriques les moins prometteuses. Lors de la comparaison des modèles MARS pour la modélisation des écoulements de débit des fuites au barrage Oued Cherf, il est devenu évident que les configurations d'entrée jouent un rôle déterminant dans l'efficacité de ces modèles. Le MARS2, en excluant les paramètres temporels au profit des données piézométriques et du CPE, a montré des performances optimales. Cette observation contraste nettement avec la faible contribution des variables liées au calendrier grégorien, comme le montrent les modèles MARS1 et MARS3. La performance inférieure du MARS3, en particulier, souligne l'importance cruciale du CPE dans le processus de modélisation. Cependant, l'uniformité des résultats entre les modèles MARS4 et MARS12 suggère la présence de problèmes potentiels, tels que le surapprentissage ou la redondance des données.

Pendant la phase d'apprentissage, le modèle M5T1, qui incluait à la fois le calendrier grégorien et les données piézométriques (PZ1-PZ9) en plus du niveau d'eau (CPE), a affiché un R de 0.791, une efficacité NSE de 0.598, une RMSE de 0.108, et une MAE de 0.079. Bien que cet ensemble de données soit complet, il n'a pas conduit à une performance optimale. D'un autre côté, le modèle M5Tree2, qui excluait les données calendaires, a montré des métriques supérieures, avec un R de 0.813 et un NSE de 0.584. Les valeurs des RMSE et MAE étaient respectivement de 0.110 et 0.083, suggérant que les données calendaires pourraient ne pas apporter une amélioration significative de la précision dans ce contexte. Le modèle M5Tree3, a intégré le calendrier grégorien mais a omis le niveau d'eau (CPE), ce qui a entraîné un R de 0.748, un NSE de 0.522, un RMSE de 0.118 et un MAE de 0.092, marquant une baisse par rapport à M5Tree2. Cette diminution met en évidence l'importance du niveau d'eau lors de l'apprentissage. Le modèle M5Tree4, qui incorporait le calendrier grégorien, les données piézométriques jusqu'à PZ8, et le niveau d'eau (CPE), a montré des améliorations significatives, enregistrant des valeurs de R, NSE, RMSE et MAE de 0.817, 0.643, 0.102, et 0.075 respectivement. De manière surprenante, les modèles M5Tree5 à M5Tree12, malgré des réductions séquentielles des données piézométriques tout en conservant à la fois le calendrier et le niveau d'eau, ont tous affiché des valeurs identiques : R à 0.860, NSE à 0.740, RMSE à 0.087, et MAE à 0.058. Cette constance suggère qu'après un certain seuil, l'ajout de données


piézométriques pourrait ne pas améliorer significativement l'efficacité de la phase d'apprentissage du modèle. Parmi tous les modèles évalués, M5Tree5 à M5Tree12 se sont distingués par leurs performances, M5Tree12 étant particulièrement remarquable pour sa simplicité. À l'inverse, le modèle M5Tree3 était le moins performant, soulignant l'importance d'inclure les données de niveau d'eau (CPE) lors de l'apprentissage.

Pendant la phase de validation, nous avons débuté avec le modèle M5Tree1, qui a obtenu un R de 0.665, un NSE de 0.441, une RMSE de 0.140 et une MAE de 0.102. Le modèle M5Tree2 a surpassé ces métriques en atteignant des valeurs de R et de NSE de 0.736 et 0.510 respectivement, ainsi que des valeurs de RMSE et de MAE de 0.131 et 0.102. En revanche, le modèle M5Tree3 a régressé, enregistrant des valeurs de R, de NSE, de RMSE et de MAE de 0.474, 0.207, 0.167 et 0.135, respectivement, réaffirmant le rôle central du niveau d'eau dans les prédictions. Le modèle M5Tree4 a affiché des métriques moyennes, avec des valeurs de R, de NSE, de RMSE et de MAE à 0.671, 0.447, 0.140 et 0.100, respectivement. Cependant, à l'instar de la phase d'apprentissage, les modèles M5Tree5 à M5Tree12 ont uniformément présenté des résultats impressionnants, chacun affichant un R de 0.744, un NSE de 0.541, un RMSE de 0.127 et un MAE de 0.087. Cela suggère à nouveau qu'une trop grande confiance en les données piézométriques pourrait ne pas garantir une précision accrue. Dans cette phase, les modèles M5Tree5 à M5Tree12 ont dominé, M5Tree12 se démarquant par sa structure plus simple. En revanche, le modèle M5Tree3 était en retrait, renforçant l'importance du niveau d'eau (CPE) pour des prédictions précises. L'inclusion et l'exclusion systématiques de différentes variables d'entrée nous ont fourni une clarté sur leurs effets sur la modélisation du débit des fuites. Le calendrier grégorien, bien qu'utile pour comprendre la chronologie, n'a pas eu d'influence constante sur les déterminations du débit des fuites. En revanche, le niveau d'eau (CPE) s'est révélé crucial. Il semble également y avoir un seuil apparent dans l'utilité des données piézométriques, au-delà duquel leur contribution à la précision stagne. Pour une modélisation efficace, l'utilisation de modèles tels que M5Tree12, qui équilibrent la complexité et la performance, pourrait être idéale.


À la lumière des résultats obtenus on peut conclure ce qui suit:

- 1) Compte tenu de leur structure basée sur des arbres, les modèles M5Tree capturent avec habileté les relations non linéaires et démontrent une résistance robuste au surapprentissage, surpassant de manière constante d'autres méthodes lors de la validation. Ainsi, pour une modélisation pratique du débit des fuites à travers le barrage, il est vivement recommandé de privilégier les modèles M5Tree, en particulier ceux qui intègrent des données piézométriques et le niveau d'eau (CPE), tels que M5Tree5 en raison de leurs performances supérieures.
- 2) Dans l'ensemble de la validation, le LSSVM2, utilisant les données piézométriques et le niveau d'eau (CPE) sans tenir compte des dates, surpasse les autres modèles LSSVM, ce qui suggère que les éléments temporels pourraient être secondaires par rapport aux données piézométriques. Les modèles MARS maintiennent leur performance à partir de MARS3, avec MARS2 se révélant comme le meilleur performeur, même en l'absence de données temporelles. Il est remarquable de constater que les modèles M5Tree, en particulier M5Tree5 à M5Tree12, surpassent à la fois les LSSVM et les modèles MARS, ce qui suggère une supériorité en termes de généralisation, surtout lorsque les données de date sont exclues et que l'accent est mis sur les mesures piézométriques et le CPE.

- 3) Une analyse des performances des modèles révèle que l'inclusion des informations de date n'entraîne pas d'amélioration significative des performances sur les trois modèles. Par exemple, le modèle LSSVM2 (sans données de date) surpasse le modèle LSSVM1 (avec données de date) à la fois en phase d'apprentissage et en phase de validation. Ces résultats suggèrent que le débit des fuites dans le barrage Foum El Khanga pourrait être davantage influencé par les données piézométriques et CPE que par des détails temporels spécifiques.
- 4) En général, les modèles comportant un nombre plus élevé de points de données piézométriques présentent de meilleures performances, ce qui met en évidence leur rôle central dans la prédiction du débit des fuites. Par exemple, le modèle LSSVM2, qui intègre les données piézométriques PZ1-PZ9 ainsi que le CPE, surpasse le modèle LSSVM12, qui se limite aux données de date et au CPE. De manière intéressante, la performance ne diminue pas de manière linéaire à mesure que l'on retire progressivement les points piézométriques, ce qui suggère que certains points de données peuvent avoir une importance plus marquée que d'autres.
- 5) Sur la base des résultats de l'étude à travers diverses approches d'IA, la combinaison d'entrées optimale pour la prédiction précise du débit des fuites englobe plusieurs points piézométriques, spécifiquement PZ1 à PZ9, couplés avec le CPE, éliminant le besoin de données de date.
- 6) Le niveau d'eau dans le réservoir, représenté par l'acronyme CPE, s'est avéré être un paramètre crucial. Des modèles tels que M1, qui ont intégré le CPE, ont largement surpassé leurs homologues comme M3, qui ne disposaient pas du CPE mais disposaient les mêmes données piézométriques.



**Figure VII. 19.** Comparaison entre les différents modèles Ensemblistes par les diagrammes en boîte (Boxplot) et en violon (Violinplot): Barrage Foum El Khanga.



**Figure VII. 20.** Le diagramme de Taylor pour la comparaison entre les meilleurs modèles ensemblistes: Barrage Foum El Khanga.

## VI.7. Résultats Obtenus par les modèles Neuroflous: Barrage Hammam Debagh

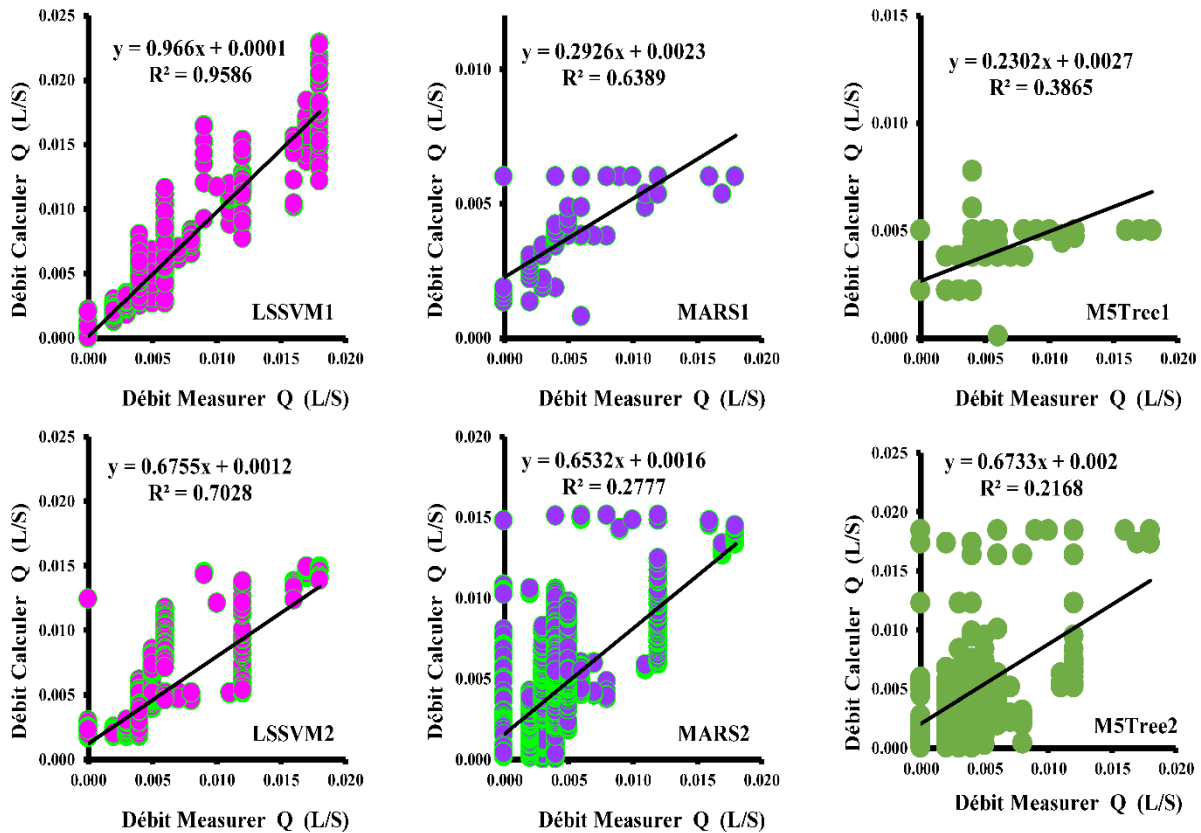
**Tableau VII.5** présente les résultats des différents modèles LSSVM, MARS, M5Tree, au niveau du barrage Hammam Debagh. Lors des phases d'apprentissage et de validation. Les modèles sont désignés par M1 et M2, avec leurs variables d'entrée et de sortie respectives. Le modèle LSSVM1 (M1) a affiché des performances remarquables, avec une valeur R presque parfaite de 0.996, indiquant une corrélation linéaire presque parfaite entre les résultats prédits et observés. Le coefficient NSE élevé de 0.992 témoigne d'un ajustement exceptionnel. De plus, la précision du modèle est mise en évidence par ses valeurs RMSE et MAE minimales, toutes deux enregistrées à 0.000. En revanche, le modèle LSSVM2 (M2), qui est configuré en utilisant uniquement CPE et le VOL comme entrées, a affiché des performances inférieures. Avec une valeur R de 0.831 et un NSE de 0.690, les résultats indiquent une relation linéaire satisfaisante et une adéquation du modèle, respectivement. Bien que les valeurs RMSE et MAE de LSSVM2 (0.002 et 0.001) soient relativement faibles, elles sont légèrement supérieures à celles de LSSVM1.

**Tableau VII. 5.** Performances des différents modèles Ensemblistes & barrage Hammam Debagh.

|         | R     | NSE   | RMSE  | MAE   | R     | NSE    | RMSE  | MAE   |
|---------|-------|-------|-------|-------|-------|--------|-------|-------|
| LSSVM1  | 0.996 | 0.992 | 0.000 | 0.000 | 0.979 | 0.958  | 0.001 | 0.000 |
| LSSVM2  | 0.831 | 0.690 | 0.002 | 0.001 | 0.838 | 0.702  | 0.002 | 0.001 |
| MARS1   | 0.827 | 0.684 | 0.002 | 0.001 | 0.799 | 0.435  | 0.002 | 0.001 |
| MARS2   | 0.668 | 0.446 | 0.002 | 0.001 | 0.527 | -0.238 | 0.003 | 0.002 |
| M5Tree1 | 0.980 | 0.961 | 0.001 | 0.000 | 0.622 | 0.318  | 0.003 | 0.001 |
| M5Tree2 | 0.905 | 0.820 | 0.001 | 0.001 | 0.466 | -0.818 | 0.004 | 0.002 |

Pendant la phase de validation, le LSSVM1 continue de présenter des résultats notables, avec une valeur R de 0.979 et un NSE de 0.958. Les valeurs RMSE et MAE (0.001 et 0.000), respectivement, soulignent la capacité du modèle à prédire des débits de fuite. En revanche, lors de la validation, le LSSVM2 a enregistré une valeur R de 0.838 et un NSE de 0.702. Les valeurs RMSE et MAE (0.002 et 0.001) sont étroitement liées à ses résultats d'apprentissage. Dans l'ensemble, LSSVM1 surpasse nettement LSSVM2 à la fois en phase d'apprentissage et en phase de validation. L'ajout de variables calendaires (YY, MM, DD) dans M1 semble renforcer ses capacités prédictives, soulignant ainsi l'importance des données de séries chronologiques. Le modèle MARS1 (M1) a affiché une valeur R de 0.827, indiquant une association linéaire louable entre les données prédites et observées. Cependant, un NSE de 0.684 suggère un ajustement modéré du modèle. Les valeurs RMSE et MAE, toutes deux notées à 0.002 et 0.001 respectivement, se situent dans des limites acceptables mais ne sont pas exceptionnelles. En revanche, MARS2 (M2) a montré une performance modérée, enregistrant une valeur R de 0.668 et un NSE de 0.446. Le RMSE et le MAE restent constants à 0.002 et 0.001 respectivement. Pour MARS1, les résultats de la validation ont montré une diminution, avec des valeurs R et NSE de 0,799 et 0,435, suggérant un potentiel de surajustement pendant l'apprentissage. Le RMSE et le MAE restent stables à 0.002 et 0.001. En revanche, lors de la validation, MARS2 a enregistré une baisse significative de performance. Avec un R de 0.527 et un NSE plongeant à -0.238, la performance du modèle a considérablement diminué, dépassant même les modèles de prédiction basés sur la moyenne. Les valeurs RMSE et MAE étaient de 0.003 et 0.002

respectivement. Après analyse, il est clair que MARS1 surpasse de manière significative MARS2 dans les deux phases. Une fois de plus, la structure du modèle M1, qui intègre des variables calendaires, prouve son efficacité.




**Figure VII. 21.** Scatterplots des valeurs des débits de fuite Q mesurées et calculées par les différents modèles Ensemblistes : barrage Hammam Debagh & phase de validation.

M5Tree1 (M1) a affiché une valeur R louable de 0.980 et NSE de 0.961, indiquant une association linéaire presque parfaite et une adaptation du modèle. Les valeurs RMSE et MAE sont de 0.001 et 0.000. Le modèle M5T2 (M2), avec des paramètres d'entrée limités à CPE et VOL, a révélé un R de 0.905 et NSE de 0.820. Bien que la performance soit robuste, elle n'est pas à la hauteur de M5Tree1. Les métriques RMSE et MAE restent constantes à 0.001. Pendant la validation, les résultats de M5Tree1 ont fortement chuté, enregistrant un R de 0.622 et un NSE de 0.318. Les valeurs RMSE et MAE ont augmenté à 0.003 et 0.001. Les métriques de validation de M5Tree2 étaient médiocres avec un R de 0.466 et un NSE gravement négatif de -0,818. Les valeurs RMSE et MAE étaient de 0.004 et 0.002, respectivement. Bien que M5Tree1 ait dominé la phase d'apprentissage, la baisse substantielle pendant la validation indique un probable surajustement. M5Tree2, malgré des métriques d'apprentissage satisfaisantes, a fortement chuté lors de la phase de validation. Parmi les approches évaluées, la structure du modèle M1, incorporant des variables calendaires, surpasse systématiquement le modèle M2, mettant en évidence le caractère crucial des données temporelles dans la prédiction de l'écoulement par infiltration. Parmi les trois techniques évaluées, LSSVM, en particulier LSSVM1, se présente comme le choix prééminent. Cependant, l'approche M5Tree, bien que prometteuse initialement, a montré une susceptibilité au surajustement, compromettant sa fiabilité pour les déploiements réels. En conclusion, la méthodologie LSSVM, avec sa structure


de modèle M1, est recommandée pour modéliser des débits de fuite au barrage de Bouhamdane, en raison de ses performances constantes à travers les phases. De plus amples recherches sont nécessaires pour discerner la supériorité des modèles exploitant les données calendaires et pour aborder les préoccupations de surajustement observées dans les modèles M5Tree.

À la lumière des résultats obtenus on peut conclure ce qui suit:

- 1) Les modèles formulés en utilisant les paramètres d'entrée encapsulés par le Modèle 1, en particulier les données calendrier grégorien (AA, MM, JJ) associées au niveau d'eau du réservoir (CPE) et au volume (VOL), démontrent une nette amélioration de leurs capacités prédictives par rapport aux modèles qui ne tiennent pas compte de les données calendrier grégorien.
- 2) Parmi les modèles analysés, LSSVM1 se démarque comme le plus performant, affichant des résultats remarquables, notamment un R de 0.979 lors de la phase de validation, ainsi qu'une erreur absolue moyenne négligeable (MAE=0,0) tout au long des phases d'apprentissage et de validation. Suivant de près LSSVM1 dans la hiérarchie des performances, nous trouvons les modèles M5Tree1 et MARS1.
- 3) Il convient de souligner particulièrement que l'efficacité du modèle LSSVM1 est profonde, surtout lors de la phase d'apprentissage, où il atteint un coefficient R dépassant 0.996.
- 4) En comparaison, les modèles élaborés à l'aide des paramètres définis par le Modèle 2 (CPE, VOL) ont montré des indicateurs de performance relativement modérés. Cependant, parmi ces modèles, LSSVM2 se démarque en atteignant des performances optimales, avec un coefficient de corrélation R de 0.838 lors de la phase de validation.
- 5) Une conclusion essentielle de cette analyse met en évidence l'influence significative des variables du calendrier grégorien (AA, MM, JJ). L'intégration de ces paramètres temporels est cruciale pour améliorer la précision des prédictions relatives au débit de fuite à travers le barrage.



**Figure VII. 22.** Comparaison entre les différents modèles Ensemblistes par les diagrammes en boîte (Boxplot) et en violon (Violinplot) : Barrage Hammam Debagh.



**Figure VII. 23.** Le diagramme de Taylor pour la comparaison entre les meilleurs modèles ensemblistes: Barrage Foug El Khanga.

## VII.8. Conclusion

Ce chapitre nous a entraînés dans une exploration approfondie des techniques avancées de modélisation, dévoilant une série d'analyses à travers divers barrages et une variété d'approches de modélisation, à savoir le LSSVM, le MARS et le M5Tree. L'ampleur de notre exploration a révélé plusieurs aperçus cruciaux qui portent de profondes implications pour le domaine de l'hydrologie et de la gestion des barrages. Tout d'abord, l'importance cruciale de la sélection judicieuse des données d'entrée a émergé comme un thème récurrent. La performance d'un modèle, comme l'illustrent à maintes reprises nos résultats, ne repose pas uniquement sur sa complexité, mais est étroitement liée à la qualité et à la pertinence de ses données d'entrée. Les données piézométriques, en particulier, ont régulièrement démontré leur rôle prépondérant dans l'amélioration de la précision des prévisions.

Deuxièmement, la relation subtile entre la complexité du modèle et sa capacité de généralisation a été exposée. Alors que les modèles complexes offrent souvent une grande fidélité lors des phases d'entraînement, leur application dans des conditions du monde réel, comme l'ont illustré plusieurs phases de validation, nécessite une prudence particulière. Le risque latent de surajustement peut potentiellement compromettre l'utilité même d'un modèle, le rendant moins fiable face à des données inattendues. La diversité des barrages examinés dans ce chapitre a également souligné qu'il n'existe pas de modèle universellement optimal. L'efficacité d'un modèle dépend souvent du contexte, façonnée par les caractéristiques uniques du barrage en question, son environnement environnant et la qualité des données disponibles.

En réfléchissant à nos résultats, bien que ce chapitre ait mis en lumière plusieurs techniques prometteuses et meilleures pratiques, il souligne également la nécessité de la recherche continue. Alors que nous progressons, que les informations obtenues ici servent à la fois de boussole et de catalyseur, guidant les futurs efforts dans la quête d'une gestion des barrages plus sûre, plus efficace et plus durable.

## **Conclusion Générale**

Cette thèse représente un examen complet et approfondi des domaines de l'hydrologie, de la gestion des barrages, et de l'utilisation émergente de l'intelligence artificielle (IA) dans la modélisation de l'infiltration. Notre exploration débute avec un retour sur l'histoire, où les barrages anciens ont joué un rôle vital dans la survie de l'humanité, et nous nous dirigeons vers les modèles de pointe basés sur l'IA qui façonnent l'avenir. Les conclusions de cette recherche ont des répercussions transformationnelles pour les domaines de l'hydrologie et de la gestion des infrastructures, en particulier en ce qui concerne les barrages en remblai de terre. Elles tracent la voie vers une gestion plus sûre, efficace et durable des ressources en eau.

Tout au long des chapitres de cette thèse, des thèmes récurrents et des découvertes cruciales ont émergé. Parmi eux, nous mettons en avant l'importance centrale de la modélisation des débits de fuite, soulignant l'importance capitale de l'estimation des pertes par infiltration pour prévenir les éventuels dommages internes aux barrages. Les méthodes traditionnelles, basées sur les techniques graphiques de réseaux de flux, ont laissé place à des méthodes numériques exploitant la puissance de calcul de l'IA. À mesure que les méthodologies de l'IA évoluent, elles renforcent considérablement notre capacité à prédire les fuites et à élaborer des stratégies de gestion des barrages plus efficaces.

Une des principales leçons de cette recherche concerne l'importance du choix judicieux des variables d'entrée pour la modélisation. Le nombre d'entrées n'est pas le seul indicateur de la qualité du modèle ; il est essentiel de sélectionner soigneusement les variables pertinentes. Cette compréhension remet en question la pratique consistant à augmenter le nombre de variables d'entrée, en soulignant les dangers du surajustement et en préconisant la collecte de données qui apportent une réelle valeur prédictive. Le rôle des données calendaires du calendrier grégorien a été identifié comme un facteur critique, ayant des impacts variables sur les performances du modèle. De même, l'inclusion des données sur le niveau d'eau des réservoirs s'est révélée être un changement majeur, un paramètre essentiel pour améliorer la précision des prédictions et une nécessité pour une gestion efficace des barrages. L'emplacement et la pertinence des points piézométriques ont montré une influence profonde sur les performances du modèle, soulignant l'importance de données de haute qualité et bien positionnées.

La recherche a également mis en lumière le compromis entre la complexité et la performance dans la modélisation. Les modèles complexes, bien qu'ils présentent souvent une grande fidélité lors de la phase d'apprentissage, doivent être utilisés avec prudence dans des situations réelles en raison du risque latent de surajustement. La simplicité, avec moins d'entrées mais soigneusement choisies, peut rivaliser efficacement avec la complexité lorsque les modèles sont adaptés aux caractéristiques uniques de chaque barrage. De plus, nous avons reconnu la diversité des barrages en tant qu'entités individuelles, chacun ayant ses propres caractéristiques hydrologiques et géologiques uniques. L'efficacité des modèles d'IA peut varier considérablement d'un barrage à l'autre, soulignant la nécessité d'adopter des approches personnalisées adaptées aux données et aux variables d'entrée distinctes de chaque cas.

Les conclusions présentées ici conduisent à l'affirmation que le chemin vers la perfection des modèles hydrologiques est un voyage dynamique et en constante évolution. Dans un monde confronté à des défis croissants liés au changement climatique, aux modèles de précipitations changeants et aux pressions anthropogéniques croissantes, le rôle de la modélisation hydrologique dans le développement de solutions durables est primordial. Les techniques avancées de l'IA sont à l'avant-garde de cette quête, offrant des perspectives prometteuses pour une gestion des barrages plus sûre, plus efficace et plus durable.

En conclusion, cette recherche a parcouru un paysage complexe, où le passé rencontre le futur, où les méthodes traditionnelles évoluent en techniques basées sur l'IA, et où chaque barrage est une entité unique avec ses propres défis. Les idées tirées de cette recherche servent de boussole, nous guidant vers de meilleures décisions, et de catalyseur, propulsant les efforts futurs dans la quête d'un avenir de gestion des ressources en eau à la fois sécurisé et durable. Les horizons de l'hydrologie et de la gestion des barrages continuent de s'élargir, alimentés par l'IA et l'engagement indéfectible à comprendre, protéger et gérer efficacement cette ressource précieuse qui est fondamentale pour la vie sur Terre.

*Références Bibliographiques*

---

- Adoko, A.-C., Jiao, Y.-Y., Wu, L., Wang, H., & Wang, Z.-H. (2013). Predicting tunnel convergence using Multivariate Adaptive Regression Spline and Artificial Neural Network. *Tunnelling and Underground Space Technology*, 38, 368–376. <https://doi.org/10.1016/j.tust.2013.07.023>
- Al-Juboori, M., & Datta, B. (2019). Performance evaluation of a genetic algorithm-based linked simulation-optimization model for optimal hydraulic seepage-related design of concrete gravity dams. *Journal of Applied Water Engineering and Research*, 7(3), 173–197. <https://doi.org/10.1080/23249676.2018.1497558>
- Anthony, M., & Bartlett, P. L. (1999). *Neural Network Learning: Theoretical Foundations*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511624216>
- Arbib, M. A. (2003). *The handbook of brain theory and neural networks* (2nd ed). MIT Press. <https://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=86054>
- Aronszajn, N. (1950). Theory of reproducing kernels. *Transactions of the American Mathematical Society*, 68(3), 337–404. <https://doi.org/10.1090/S0002-9947-1950-0051437-7>
- Baesens, B., Viaene, S., Van Gestel, T., Suykens, J. A. K., Dedene, G., De Moor, B., & Vanthienen, J. (2000). An empirical assessment of kernel type performance for least squares support vector machine classifiers. *KES'2000. Fourth International Conference on Knowledge-Based Intelligent Engineering Systems and Allied Technologies. Proceedings (Cat. No.00TH8516)*, 1, 313–316 vol.1. <https://doi.org/10.1109/KES.2000.885819>
- Baker, C. T. H., & Taylor, R. L. (1979). The Numerical Treatment of Integral Equations. *Journal of Applied Mechanics*, 46(4), 969. <https://doi.org/10.1115/1.3424708>
- Bartlett, P. L., & Mendelson, S. (2001). Rademacher and Gaussian Complexities: Risk Bounds and Structural Results. In D. Helmbold & B. Williamson (Eds.), *Computational Learning Theory* (pp. 224–240). Springer. [https://doi.org/10.1007/3-540-44581-1\\_15](https://doi.org/10.1007/3-540-44581-1_15)
- Belmokre, A., Mihoubi, M. K., & Santillan, D. (2019). Seepage and dam deformation analyses with statistical models: Support vector regression machine and random forest. *Procedia Structural Integrity*, 17, 698–703. <https://doi.org/10.1016/j.prostr.2019.08.093>
- Breth, H. (1972). Der derzeitige Stand des Staudammbaues. *Wasserwirtschaft*, 62, 1.
- Broomhead, D., & Lowe, D. (1988). *Multivariable functional interpolation and adaptive networks, complex systems, vol. 2*.
- Casagrande, A. (1948). Research on stress-deformation and strength characteristics of soil and soft rocks under transient loading. *Harvard Soil Mechanics Series*, 31.
- Cedergren, H. R. (1977). *SEEPAGE, DRAINAGE AND FLOW NETS. 2ND EDITION* (Monograph). <https://trid.trb.org/view/76314>
- Chen, S., Gu, C., Lin, C., Wang, Y., & Hariri-Ardebili, M. A. (2020). Prediction, monitoring, and interpretation of dam leakage flow via adaptative kernel extreme learning machine. *Measurement*, 166, 108161. <https://doi.org/10.1016/j.measurement.2020.108161>
- Chen, S., Mulgrew, B., & McLaughlin, S. (1992). Adaptive Bayesian decision feedback equaliser based on a radial basis function network. *[Conference Record] SUPERCOMM/ICC '92 Discovering a New World of Communications*, 1267–1271 vol.3. <https://doi.org/10.1109/ICC.1992.268037>
- Chen, X., An, Y., Zhang, Z., & Li, Y. (2020). An approximate nondominated sorting genetic algorithm to integrate optimization of production scheduling and accurate maintenance

- based on reliability intervals. *Journal of Manufacturing Systems*, 54, 227–241. <https://doi.org/10.1016/j.jmsy.2019.12.004>
- Cigizoglu, H. K., & Kişi, Ö. (2005). Flow prediction by three back propagation techniques using k-fold partitioning of neural network training data. *Hydrology Research*, 36(1), 49–64. <https://doi.org/10.2166/nh.2005.0005>
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*, 2(4), 303–314. <https://doi.org/10.1007/BF02551274>
- de Granrut, M., Simon, A., & Dias, D. (2019). Artificial neural networks for the interpretation of piezometric levels at the rock-concrete interface of arch dams. *Engineering Structures*, 178, 616–634. <https://doi.org/10.1016/j.engstruct.2018.10.033>
- El Bilali, A., Moukhliiss, M., Taleb, A., Nafii, A., Alabjah, B., Brouziyne, Y., Mazigh, N., Tezine, K., & Mhamed, M. (2022). Predicting daily pore water pressure in embankment dam: Empowering Machine Learning-based modeling. *Environmental Science and Pollution Research*, 29(31), 47382–47398. <https://doi.org/10.1007/s11356-022-18559-7>
- El-Bakry, M. Y. (2003). Feed forward neural networks modeling for K–P interactions. *Chaos, Solitons & Fractals*, 18(5), 995–1000. [https://doi.org/10.1016/S0960-0779\(03\)00068-7](https://doi.org/10.1016/S0960-0779(03)00068-7)
- Friedman, J. H. (1991). Multivariate Adaptive Regression Splines. *The Annals of Statistics*, 19(1), 1–67. <https://doi.org/10.1214/aos/1176347963>
- Hagan, M. T., & Menhaj, M. B. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989–993. <https://doi.org/10.1109/72.329697>
- Haykin, S. (1994). Intelligent Signal Processing. In X. P. V. Maldague (Ed.), *Advances in Signal Processing for Nondestructive Evaluation of Materials* (pp. 1–12). Springer Netherlands. [https://doi.org/10.1007/978-94-011-1056-3\\_1](https://doi.org/10.1007/978-94-011-1056-3_1)
- Haykin, S. S. (2009). *Neural networks and learning machines/Simon Haykin*. New York: Prentice Hall.
- Hebb, D. (1949). *The organization of behavior. EmphNew york*. Wiley.
- Heydari, M., & Talaei, P. H. (2011). Prediction of flow through rockfill dams using a neuro-fuzzy computing technique. *J Math Comput Sci*, 2(3), 515–528.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359–366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)
- Horsky, O. (1969). Seepage from the Dam Foix in calcareous karst. *Vodni Hospodgrstvi, Prague*, 7, 201.
- Ishfaque, M., Salman, S., Jadoon, K. Z., Danish, A. A. K., Bangash, K. U., & Qianwei, D. (2022). Understanding the Effect of Hydro-Climatological Parameters on Dam Seepage Using Shapley Additive Explanation (SHAP): A Case Study of Earth-Fill Tarbela Dam, Pakistan. *Water*, 14(17), Article 17. <https://doi.org/10.3390/w14172598>
- JAMEL, A. A. J., & ALI, M. I. (2021). Stability and seepage of earth dams with toe filter (Calibrated with Artificial Neural Network). *Journal of Engineering Science and Technology*, 16(5), 3712–3725.
- Jang, J.-S. R. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665–685. <https://doi.org/10.1109/21.256541>
- Jenner, M. (1983). *Jemen neu entdeckt*. Longman.
- Jiang, A. N., & Liang, B. (2006). Nonlinear time series prediction model for dam seepage flow based on PSO-SVM. *Journal of Hydraulic Engineering*, 37(3), 331–335.
- Justin, J. D. W. (1932). *Earth Dam Projects*. J. Wiley & Sons, Incorporated.

- Kanchanaphol, L., Mahasandana, T., & Bucharoen, V. (1982). Geology of Srinagarind dam, foundation treatment and evaluation of grouting efficiency. *14th ICOLD-Congress, II*: 7-35.
- Karapataki, C., & Adamowski, J. (2012). Closure to “Comparison of Multivariate Regression and Artificial Neural Networks for Peak Urban Water-Demand Forecasting: Evaluation of Different ANN Learning Algorithms” by Jan Adamowski and Christina Karapataki. *Journal of Hydrologic Engineering*, *17*(7), 834–836. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000472](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000472)
- Khoramshokoh, N., Veiskarami, M., Nikoo, M. R., & Pourvahedi Roshandeh, S. (2018). Multi-objective hydraulic optimization of diversion dam’s cut-off. *Water Resources Management*, *32*, 3723–3736.
- Kisi, O. (2015a). Pan evaporation modeling using least square support vector machine, multivariate adaptive regression splines and M5 model tree. *Journal of Hydrology*, *528*, 312–320. <https://doi.org/10.1016/j.jhydrol.2015.06.052>
- Kisi, O. (2015b). Streamflow Forecasting and Estimation Using Least Square Support Vector Regression and Adaptive Neuro-Fuzzy Embedded Fuzzy c-means Clustering. *Water Resources Management*, *29*(14), 5109–5127. <https://doi.org/10.1007/s11269-015-1107-7>
- Kisi, O., & Parmar, K. S. (2016). Application of least square support vector machine and multivariate adaptive regression spline models in long term prediction of river water pollution. *Journal of Hydrology*, *534*, 104–112. <https://doi.org/10.1016/j.jhydrol.2015.12.014>
- Kumar, V., Samui, P., Himanshu, N., & Burman, A. (2019). Reliability-Based Slope Stability Analysis of Durgawati Earthen Dam Considering Steady and Transient State Seepage Conditions Using MARS and RVM. *Indian Geotechnical Journal*, *49*(6), 650–666. <https://doi.org/10.1007/s40098-019-00373-7>
- Kutzner, C. (1988). Impact of reservoir filling on the environment close downstream (Kinda dam Burma). *16th ICOLD-Congress, I*: 113-125.
- Kutzner, C. (1997). *Earth and Rockfill Dams: Principles for Design and Construction*. Routledge. <https://doi.org/10.1201/9780203758991>
- Lera, G., & Pinzolas, M. (1998). A quasi-local Levenberg-Marquardt algorithm for neural network training. *1998 IEEE International Joint Conference on Neural Networks Proceedings. IEEE World Congress on Computational Intelligence (Cat. No.98CH36227)*, *3*, 2242–2246 vol.3. <https://doi.org/10.1109/IJCNN.1998.687209>
- Li, X., Wen, Z., & Su, H. (2021). An approach using random forest intelligent algorithm to construct a monitoring model for dam safety. *Engineering with Computers*, *37*(1), 39–56. <https://doi.org/10.1007/s00366-019-00806-0>
- Makra, A. (2013). *Evaluation of the UBC3D-PLM constitutive model for prediction of earthquake induced liquefaction on embankment dams*.
- Markovic, M., Brankovic, J. M., Stosovic, M. A., Zivkovic, S., & Brankovic, B. (2021). A new method for pore pressure prediction on malfunctioning cells using artificial neural networks. *Water Resources Management*, *35*, 979–992.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, *5*(4), 115–133. <https://doi.org/10.1007/BF02478259>
- Melin, P., Soto, J., Castillo, O., & Soria, J. (2012). A new approach for time series prediction using ensembles of ANFIS models. *Expert Systems with Applications*, *39*(3), 3494–3506. <https://doi.org/10.1016/j.eswa.2011.09.040>

- Miao, X. Y., Chu, J. K., Qiao, J., & Zhang, L. H. (2012). Predicting Seepage of Earth Dams Using Neural Network and Genetic Algorithm. *Advanced Materials Research*, 403–408, 3081–3085. <https://doi.org/10.4028/www.scientific.net/AMR.403-408.3081>
- Moody, J., & Darken, C. J. (1989). Fast Learning in Networks of Locally-Tuned Processing Units. *Neural Computation*, 1(2), 281–294. <https://doi.org/10.1162/neco.1989.1.2.281>
- Mulgrew, B. (1996). *Applying radial basis functions*, *IEEE Signal Proc. Magazine*.
- Najafzadeh, M. (2020). Projection of seepage and piezometric pressure in earth dams using soft computational models. *Amirkabir Journal of Civil Engineering*, 52(7), 1783–1796.
- Norak, P., Moffat, A. I. B., Nalluria, C., & Narayanan, R. (2007). *Hydraulic Structures P. Novak*.
- Norman, S. (1971). A history of dams. *Peter Davies: London, UK*, 25–49.
- Nourani, V., & Babakhani, A. (2013). Integration of Artificial Neural Networks with Radial Basis Function Interpolation in Earthfill Dam Seepage Modeling. *Journal of Computing in Civil Engineering*, 27(2), 183–195. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000200](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000200)
- Pal, M., & Deswal, S. (2009). M5 model tree based modelling of reference evapotranspiration. *Hydrological Processes*, 23(10), 1437–1443. <https://doi.org/10.1002/hyp.7266>
- Park, J.-W., Harley, R. G., & Venayagamoorthy, G. K. (2002). Comparison of MLP and RBF neural networks using deviation signals for indirect adaptive control of a synchronous generator. *Proceedings of the 2002 International Joint Conference on Neural Networks. IJCNN'02 (Cat. No.02CH37290)*, 1, 919–924 vol.1. <https://doi.org/10.1109/IJCNN.2002.1005597>
- Parlos, A. G., Atiya, A. F., Chong, K. T., & Tsai, W. K. (1992). Nonlinear Identification of Process Dynamics Using Neural Networks. *Nuclear Technology*, 97(1), 79–96. <https://doi.org/10.13182/NT92-A34628>
- Parsaie, A., Haghiabi, A. H., Latif, S. D., & Tripathi, R. P. (2021). Predictive modelling of piezometric head and seepage discharge in earth dam using soft computational models. *Environmental Science and Pollution Research*, 28(43), 60842–60856. <https://doi.org/10.1007/s11356-021-15029-4>
- Poggio, T., & Girosi, F. (1990). Regularization algorithms for learning that are equivalent to multilayer networks. *Science*, 247(4945), 978–982.
- Quinlan, J. R. (1992). Learning with continuous classes. *5th Australian Joint Conference on Artificial Intelligence*, 92, 343–348.
- Ranković, V., Novaković, A., Grujović, N., Divac, D., & Milivojević, N. (2014). Predicting piezometric water level in dams via artificial neural networks. *Neural Computing and Applications*, 24(5), 1115–1121. <https://doi.org/10.1007/s00521-012-1334-2>
- Rehamnia, I., Benlaoukli, B., & Heddami, S. (2020). Modeling of Seepage Flow Through Concrete Face Rockfill and Embankment Dams Using Three Heuristic Artificial Intelligence Approaches: A Comparative Study. *Environmental Processes*, 7(1), 367–381. <https://doi.org/10.1007/s40710-019-00414-6>
- Rehamnia, I., Benlaoukli, B., Jamei, M., Karbasi, M., & Malik, A. (2021). Simulation of seepage flow through embankment dam by using a novel extended Kalman filter based neural network paradigm: Case study of Fontaine Gazelles Dam, Algeria. *Measurement*, 176, 109219. <https://doi.org/10.1016/j.measurement.2021.109219>
- Ren, Q., Li, M., Song, L., & Liu, H. (2020). An optimized combination prediction model for concrete dam deformation considering quantitative evaluation and hysteresis correction. *Advanced Engineering Informatics*, 46, 101154. <https://doi.org/10.1016/j.aei.2020.101154>
- Roushangar, K., Garekhani, S., & Alizadeh, F. (2016). Forecasting Daily Seepage Discharge of an Earth Dam Using Wavelet–Mutual Information–Gaussian Process Regression

- Approches. *Geotechnical and Geological Engineering*, 34(5), 1313–1326. <https://doi.org/10.1007/s10706-016-0044-4>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), Article 6088. <https://doi.org/10.1038/323533a0>
- Saleh, L. A. (2018). Studying the seepage phenomena under a concrete dam using SEEP/W and Artificial Neural Network models. *IOP Conference Series: Materials Science and Engineering*, 433(1), 012029. <https://doi.org/10.1088/1757-899X/433/1/012029>
- Salmasi, F., & Nouri, M. (2019). Effect of upstream semi-impervious blanket of embankment dams on seepage. *ISH Journal of Hydraulic Engineering*, 25(2), 143–152. <https://doi.org/10.1080/09715010.2017.1381862>
- Samui, P., & Kothari, D. P. (2011). Utilization of a least square support vector machine (LSSVM) for slope stability analysis. *Scientia Iranica*, 18(1), 53–58. <https://doi.org/10.1016/j.scient.2011.03.007>
- Schmidt, M. (1989). *Die Wasserwirtschaft des Oberharzer, Schriftenreihe der Frontius-Gesellschaft 13*.
- Schnitter, N. J. (1987). Verzeichnis geschichtlicher Talsperren bis Ende des 17. Jahrhunderts. *Historische Talsperren*, 9–20.
- Schnitter, N. J. (1994). A History of Dams: The Useful Pyramids, Rotterdam. *Netherlands, AA Balkema*.
- Seed, H. B. (1979). Considerations in the earthquake-resistant design of earth and rockfill dams. *Géotechnique*, 29(3), 215–263. <https://doi.org/10.1680/geot.1979.29.3.215>
- Sharghi, E., Nourani, V., & Behfar, N. (2018). Earthfill dam seepage analysis using ensemble artificial intelligence based modeling. *Journal of Hydroinformatics*, 20(5), 1071–1084. <https://doi.org/10.2166/hydro.2018.151>
- Sharghi, E., Nourani, V., Behfar, N., & Tayfur, G. (2019). Data pre-post processing methods in AI-based modeling of seepage through earthen dams. *Measurement*, 147, 106820. <https://doi.org/10.1016/j.measurement.2019.07.048>
- Sherard, J. L., Woodward, R. J., Gizienski, S. F., & Clevenger, W. A. (1967). *Earth and earth-rock dams*. Wiley NY.
- Specht, D. F. (1991). A general regression neural network. *IEEE Transactions on Neural Networks*, 2(6), 568–576.
- Su, H., Chen, Z., & Wen, Z. (2016). Performance improvement method of support vector machine-based model monitoring dam safety. *Structural Control and Health Monitoring*, 23(2), 252–266. <https://doi.org/10.1002/stc.1767>
- Sun, Z., Deng, Z., & Z.X.Zhang. (2011). *Intelligent control theory and technology*.
- Suykens, J. A. K., & Vandewalle, J. (1999). Least Squares Support Vector Machine Classifiers. *Neural Processing Letters*, 9(3), 293–300. <https://doi.org/10.1023/A:1018628609742>
- Taurino, A. M., Distanto, C., Siciliano, P., & Vasanelli, L. (2003). Quantitative and qualitative analysis of VOCs mixtures by means of a microsenors array and different evaluation methods. *Sensors and Actuators B: Chemical*, 93(1), 117–125. [https://doi.org/10.1016/S0925-4005\(03\)00241-7](https://doi.org/10.1016/S0925-4005(03)00241-7)
- Terzaghi, K. (1925). *Erdbaumechanik auf bodenphysikalischer Grundlage*. F. Deuticke.
- Thomas, H. H. (1978). *The engineering of large dams* [Thesis, University Of Tasmania]. <https://doi.org/10.25959/23241434.v1>
- Tinoco, J., de Granrut, M., Dias, D., Miranda, T., & Simon, A.-G. (2020). Piezometric level prediction based on data mining techniques. *Neural Computing and Applications*, 32(8), 4009–4024. <https://doi.org/10.1007/s00521-019-04392-6>
- Tsoukalas, L. H., & Uhrig, R. E. (1996). *Fuzzy and neural approaches in engineering*. John Wiley & Sons, Inc.

- Vaezinejad, S. M., Marandi, S. M., & Salajegheh, E. (2018). Inverse modelling of leakage through earth dams (case study: Baft dam, Iran). *Geotechnical Research*, 5(4), 218–230. <https://doi.org/10.1680/jgere.17.00021>
- Vallejo, L. E. (1995). Fractal analysis of granular materials. *Geotechnique*, 45(1), 159–163.
- Vapnik, V. N. (1995). Introduction: Four Periods in the Research of the Learning Problem. In V. N. Vapnik (Ed.), *The Nature of Statistical Learning Theory* (pp. 1–14). Springer. [https://doi.org/10.1007/978-1-4757-2440-0\\_1](https://doi.org/10.1007/978-1-4757-2440-0_1)
- Vaughan, P. R. (1970). Cracking and erosion of the rolled clay core of Balderhead Dam and the measures adopted for its repair. *Trans. 10th Int. Congr. Large Dams, Montreal, 1970, 1*, 73–93.
- Wang, S., Xu, Y., Gu, C., & Bao, T. (2018). Monitoring models for base flow effect and daily variation of dam seepage elements considering time lag effect. *Water Science and Engineering*, 11(4), 344–354. <https://doi.org/10.1016/j.wse.2018.12.004>
- Wasserman, P. D. (1993). *Advanced Methods in Neural Computing*. Van Nostrand Reinhold.
- Xue, X., & Xiao, M. (2019). Application of adaptive neuro-fuzzy inference system for prediction of internal stability of soils. *European Journal of Environmental and Civil Engineering*, 23(2), 153–171. <https://doi.org/10.1080/19648189.2016.1271363>
- Zhang, K., Gu, C., Zhu, Y., Chen, S., Dai, B., Li, Y., & Shu, X. (2021). A Novel Seepage Behavior Prediction and Lag Process Identification Method for Concrete Dams Using HGWO-XGBoost Model. *IEEE Access*, 9, 23311–23325. <https://doi.org/10.1109/ACCESS.2021.3056588>
- Zhang, X., Chen, X., & Li, J. (2020). Improving Dam Seepage Prediction Using Back-Propagation Neural Network and Genetic Algorithm. *Mathematical Problems in Engineering*, 2020, e1404295. <https://doi.org/10.1155/2020/1404295>
- Zhou, C.-B., Liu, W., Chen, Y.-F., Hu, R., & Wei, K. (2015). Inverse modeling of leakage through a rockfill dam foundation during its construction stage using transient flow model, neural network and genetic algorithm. *Engineering Geology*, 187, 183–195. <https://doi.org/10.1016/j.enggeo.2015.01.008>
- Ziggah, Y. Y., Issaka, Y., & Laari, P. B. (2022). Evaluation of different artificial intelligent methods for predicting dam piezometric water level. *Modeling Earth Systems and Environment*, 8(2), 2715–2731. <https://doi.org/10.1007/s40808-021-01263-9>

**USAED.K:** United States Army Engineer District, Philadelphie.

**USAED.P:** United States Army Engineer District, Kansas City.

**(U.S. DI, BR, 1977) :** United States Department of the Interior, Bureau of Reclamation, 1977, Design of small dams: Washington, U.S. Government Printing Office.

**USBR, (1991),** United States Bureau of Reclamation, Training Aid for dam safety on evaluation of seepage condition

**USBR, (1991),** United States Bureau of Reclamation, Training Aid for dam safety on slope stability and deformation.

**ICOLD:** International Commission on Large Dams, Paris, France