



**HAL**  
open science

# Caractérisation et modélisation hydrodynamique des karsts par réseaux de neurones : application à l'hydrosystème du Lez

Virgile Taver

► **To cite this version:**

Virgile Taver. Caractérisation et modélisation hydrodynamique des karsts par réseaux de neurones : application à l'hydrosystème du Lez. Réseau de neurones [cs.NE]. Université Montpellier II - Sciences et Techniques du Languedoc, 2014. Français. NNT : 2014MON20169 . tel-01811026

**HAL Id: tel-01811026**

**<https://theses.hal.science/tel-01811026>**

Submitted on 8 Jun 2018

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# THÈSE

Pour obtenir le grade de  
Docteur

Délivré par **Université Montpellier 2**

Préparée au sein de l'école doctorale **SIBAGHE**  
Et des unités de recherche : **Laboratoire de Génie de  
l'Environnement Industriel (Ecole des Mines d'Alès) et  
Hydrosciences Montpellier (Université Montpellier 2)**

**Spécialité : Eaux Continentales et Société**

Présentée par **Taver Virgile**

**Caractérisation et modélisation  
hydrodynamique des karsts par réseaux de  
neurones.**

**Application à l'hydrosystème du Lez**

Soutenue le 16/12/2014 devant le jury composé de

|   |                    |
|---|--------------------|
| Mme Anne JOHANNET, Maître de Recherche, EMA             | Directeur de thèse |
| Mr Séverin PISTRE, Professeur, UM2                      | Directeur de thèse |
| Mr Alain MANGIN, Retraité, Directeur de recherche, CNRS | Rapporteur         |
| Mr Didier GRAILLOT, Directeur de Recherche, EMSE        | Rapporteur         |
| Mr Pierre ROUSSEL RAGOT, Maître de conférences, ESPCI   | Examineur          |
| Mr Christian LEDUC, Directeur de Recherche, IRD         | Examineur          |
| Mme Valérie BORRELL ESTUPINA, Maître de conférence, UM2 | Encadrant invité   |
| Mr Marc VINCHES, Maître-Assistant, EMA                  | Encadrant invité   |





# REMERCIEMENTS

Je tiens en premier lieu à remercier toute mon équipe d'encadrement. Valérie pour sa bonne humeur et son rire retentissant dans les couloirs de la MSE, merci de m'avoir aiguillé sur cette thèse. Marc pour sa sympathie et ses compétences en géostatistiques. Un grand merci à Séverin d'avoir placé sa confiance en moi et d'avoir tenu le coup face à mes développements parfois incompréhensibles. Un très grand merci à Anne pour sa présence, son implication et pour tous nos échanges qui m'ont permis d'aboutir aux résultats présentés dans ce manuscrit. A tous les quatre, merci pour cette aventure humaine et intellectuelle au cours de laquelle nous avons pu aussi partager des moments de détente hors du boulot.

Merci à Monsieur Miguel Lopez-Ferber, puis à Monsieur Yannick Vimont de m'avoir accueilli au sein du LGEI. Mes remerciements à Monsieur Eric Servat pour l'accueil au sein du laboratoire HydroSciences.

A Messieurs Alain Mangin et Didier Graillot, j'adresse toute ma gratitude pour avoir accepté d'être les rapporteurs de ce travail.

Je remercie Messieurs Christian Leduc et Pierre Roussel pour avoir accepté d'évaluer mon travail, mais aussi pour avoir participé avec Philippe Audra à mes comités de thèses. Leurs conseils précieux ont contribué à orienter mes travaux.

J'adresse des remerciements particuliers à Dominique Bertin et son entreprise Geonosis pour le logiciel RnfPro que j'ai eu la chance de pouvoir utiliser dans le cadre de ma thèse. Pour son implication et son investissement à l'implémentation du modèle en fonction de nos besoins.

Je remercie Monsieur Henri Paloc pour m'avoir accueilli chez lui pour discuter du Lez et me faire profiter de ses connaissances, mais aussi de ses anecdotes, de sa vitalité et de son amour du karst.

Merci aux acteurs de l'observatoire MEDYCYSS, du SO Karst et du projet Lez Gestion Multi-Usages pour cette émulation autour de l'hydrosystème du Lez.

Merci aux personnels administratifs des labos où j'ai été accueilli pour m'avoir accompagné dans mes démarches et organisations de déplacements.

A toutes les personnes de l'Ecole des Mines que j'ai eu l'occasion de fréquenter, aux membres de l'équipe avec qui j'ai évolué depuis le début, aux autres thésards et stagiaires avec qui j'ai partagé mon quotidien et particulièrement mes colocataires avec qui j'ai eu plaisir à vivre et à échanger, à tous merci. Merci aussi à Line dont j'ai pris le flambeau et avec qui j'ai pu apprendre beaucoup, merci aussi de m'avoir converti à la Slackline !

J'adresse aussi mes remerciements à ceux du laboratoire HydroSciences que je côtoie depuis déjà un certain nombre d'année, certains d'entre vous ont contribué à ce que j'en arrive jusqu'ou j'en suis aujourd'hui. Merci aussi aux autres thésards du labo avec qui j'ai pu échanger, mais aussi décompresser. Un merci à Vivien de m'avoir fait sortir de mon PC pour des activités en tous genres : bricolage, terrain, expériences et balles de ping pong, sans oublier l'escalade et surtout le bloc....

J'exprime maintenant ma gratitude à mes amis de toujours, mes potes de Perpignan, mais aussi aux plus récents rencontrés lors de mon cursus universitaire, ceux avec qui j'ai vécu en collocation, pour tous les moments partagés et votre présence malgré la distance pour certains.

Je tiens à remercier ma famille et ma belle-famille pour leur soutien, mon frère, ma sœur et sa petite famille, et particulièrement mes parents et ma grand-mère qui m'ont permis de faire des études et d'arriver où j'en suis aujourd'hui.

Enfin, merci à Sandra, Norah et Jalan pour votre présence, votre affection et tout ce que vous m'apportez chaque jour. Ce travail est aussi le vôtre ...

# SOMMAIRE

|  |           |
|--|-----------|
| <b>RESUME .....</b>  | <b>15</b> |
| <b>ABSTRACT .....</b>  | <b>15</b> |
| <b>INTRODUCTION.....</b>   | <b>17</b> |
| <b>1. LES HYDROSYSTEMES KARSTIQUES .....</b>   | <b>19</b> |
| <b>1.1. LE KARST : DEFINITIONS .....</b>   | <b>19</b> |
| 1.1.1. Premières définitions historiques : morphologie karstique .....   | 19        |
| 1.1.2. Processus de karstification .....   | 20        |
| <b>1.2. REPRESENTATIONS CONCEPTUELLES DU KARST.....</b>  | <b>22</b> |
| <b>1.3. REPRESENTATION FONCTIONNELLE DU KARST .....</b>  | <b>24</b> |
| 1.3.1. Entrée de l'hydrosystème : alimentation de l'aquifère .....   | 24        |
| 1.3.2. Infiltration et transfert vers la zone saturée.....   | 25        |
| 1.3.3. Transferts dans la zone saturée.....  | 26        |
| 1.3.3.1. Réseau de drainage principal.....   | 26        |
| 1.3.3.2. « Systèmes annexes » au drainage.....   | 26        |
| 1.3.4. Connectivité régionale et effets seuil .....  | 28        |
| 1.3.5. Perturbations naturelles et anthropiques du fonctionnement de l'aquifère .....  | 28        |
| 1.3.6. Echelles temporelles de l'hydrodynamique karstique.....   | 28        |
| <b>1.4. APPROCHES ET METHODES DE CARACTERISATION, DE COMPREHENSION ET DE REPRESENTATION DU FONCTIONNEMENT HYDRODYNAMIQUE DU KARST.....</b> | <b>29</b> |
| 1.4.1. Observation .....   | 29        |
| 1.4.2. Caractérisation et conceptualisation .....  | 29        |
| 1.4.3. Modélisation .....  | 30        |
| 1.4.4. Evaluation et validation .....  | 31        |
| <b>1.5. CONCLUSION DU CHAPITRE 1.....</b>  | <b>32</b> |
| <b>2. APPROCHE SYSTEMIQUE : METHODES D'ANALYSE ET DE PRETRAITEMENT .....</b>   | <b>33</b> |
| <b>2.1. SCHEMA FONCTIONNEL ET APPROCHE SYSTEMIQUE DU KARST .....</b>   | <b>33</b> |
| <b>2.2. ANALYSE SYSTEMIQUE DU KARST ET DE SES ECHELLES TEMPORELLES.....</b>  | <b>34</b> |
| 2.2.1. Présentation des méthodes.....  | 34        |
| 2.2.1.1. Introduction .....  | 34        |
| 2.1.1.1. Analyses simples .....  | 36        |
| 2.1.1.2. Analyses croisées .....   | 37        |
| 2.2.2. Cas des systèmes non-linéaires et non-stationnaires.....  | 39        |
| 2.2.2.1. Domaine temporel.....   | 39        |

|   |            |
|---|------------|
| 2.2.2.2. <i>Domaine fréquentiel</i> .....   | 40         |
| <b>2.3. METHODES DE PRETRAITEMENT TEMPOREL DES SIGNAUX</b> .....  | <b>40</b>  |
| 2.3.1. Introduction .....   | 40         |
| 2.3.2. Méthodes de filtrage .....   | 41         |
| 2.3.2.1. <i>Choix du type de filtre utilisé</i> .....   | 41         |
| 2.3.2.2. <i>Décomposition multirésolution par filtrage passe-bande</i> .....  | 42         |
| 2.3.3. Conclusion sur le prétraitement des signaux.....   | 43         |
| <b>2.2. CONCLUSIONS SUR L'UTILISATION DE L'APPROCHE SYSTEMIQUE A L'ETUDE DES KARSTS ET DU PRETRAITEMENT DES SERIES CHRONOLOGIQUES</b> .....                                 | <b>44</b>  |
| <b>3. L'APPRENTISSAGE STATISTIQUE POUR L'ETUDE ET LA MODELISATION DES SYSTEMES NON-STATIONNAIRES</b> .....  | <b>45</b>  |
| <b>3.1. INTRODUCTION</b> .....  | <b>45</b>  |
| <b>3.2. LES RESEAUX DE NEURONES POUR L'ETUDE, LA MODELISATION ET LA PREVISION DU FONCTIONNEMENT HYDRODYNAMIQUE DU KARST</b> .....   | <b>46</b>  |
| 3.2.1. Préambule.....   | 46         |
| 3.2.2. Article sur L'apprentissage statistique pour la modélisation des hydrosystèmes karstiques .....  | 46         |
| 3.2.3. Compléments à l'article .....  | 77         |
| 3.2.3.1. <i>Formalisation mathématique</i> .....  | 77         |
| 3.2.3.2. <i>Contraindre et exploiter les modèles</i> .....  | 79         |
| 3.2.4. Conclusions sur les réseaux de neurones appliqués à la modélisation hydrodynamique des karsts..  | 79         |
| <b>3.3. RESEAUX DE NEURONES ET NON-STATIONNARITE</b> .....  | <b>80</b>  |
| 3.3.1. Introduction .....   | 80         |
| 3.3.2. Les modèles de réseaux de neurones non-récurrents et récurrents pour modéliser les non-stationnarités en utilisant l'assimilation de données et l'adaptativité. .... | 80         |
| <i>Résumé</i> :.....  | 80         |
| 3.3.3. À retenir .....  | 119        |
| <b>3.4. CONCLUSIONS GENERALES DU CHAPITRE 3</b> .....   | <b>119</b> |
| <b>4. L'AQUIFERE KARSTIQUE DU LEZ</b> .....   | <b>123</b> |
| <b>4.1. INTRODUCTION</b> .....  | <b>123</b> |
| <b>4.2. CONTEXTE</b> .....  | <b>124</b> |
| 4.2.1. Géographie et climat .....   | 124        |
| 4.2.2. Hydrographie .....   | 126        |
| 4.2.3. Exploitation de la source du Lez .....   | 127        |
| 4.2.4. Géologie.....  | 128        |
| 4.2.4.1. <i>Histoire géologique régionale</i> .....   | 128        |
| 4.2.4.2. <i>Structure géologique du bassin du Lez</i> .....   | 131        |
| <b>4.3. HYDROGEOLOGIE</b> .....   | <b>132</b> |
| 4.3.1. Karstification .....   | 132        |
| 4.3.2. Hydrodynamique .....   | 133        |

|             |  |            |
|-------------|--|------------|
| 4.3.2.1.    | <i>Introduction</i> .....  | 133        |
| 4.1.1.1.    | <i>Alimentation du système et exutoires temporaires</i> .....  | 134        |
| 4.1.1.2.    | <i>Circulations souterraines</i> .....   | 136        |
| <b>4.4.</b> | <b>LES MODELISATIONS HYDRODYNAMIQUES DE L'HYDROSYSTEME LEZ</b> .....   | <b>139</b> |
| <b>4.5.</b> | <b>CONCLUSION</b> .....  | <b>140</b> |
| <b>5.</b>   | <b>ETUDE DU FONCTIONNEMENT HYDRODYNAMIQUE DE LA SOURCE DU LEZ, EN REGIME NATUREL : AMELIORER LES MODELES POUR EN EXTRAIRE DE L'INFORMATION</b> ..... | <b>143</b> |
| <b>5.1.</b> | <b>INTRODUCTION</b> .....  | <b>143</b> |
| <b>5.2.</b> | <b>DESCRIPTION STATISTIQUE ET ANALYSES LINEAIRES DE LA RELATION PLUIE-DEBIT</b> .....  | <b>144</b> |
| 5.2.1.      | Analyse des données .....  | 144        |
| 5.2.1.1.    | <i>Présentation des données</i> .....  | 144        |
| 5.2.1.2.    | <i>Analyse du signal de pluie</i> .....  | 145        |
| 5.2.1.3.    | <i>Analyse du signal de débit</i> .....  | 148        |
| 5.2.2.      | Analyse du système .....   | 153        |
| 5.2.2.1.    | <i>Analyse de la Fonction de transfert</i> .....   | 154        |
| 5.2.2.2.    | <i>Analyse de la réponse impulsionnelle</i> .....  | 155        |
| 5.2.3.      | Conclusions sur l'analyse des signaux et du système .....  | 156        |
| <b>5.3.</b> | <b>SELECTION D'UN MODELE RECURRENT PAR VALIDATION CROISEE</b> .....  | <b>157</b> |
| 5.3.1.      | Données utilisées .....  | 157        |
| 5.3.2.      | Architecture et Sélection du modèle .....  | 157        |
| 5.3.3.      | Discussion des résultats .....   | 158        |
| 5.3.4.      | Conclusions sur le modèle ANN .....  | 159        |
| <b>5.4.</b> | <b>DECOMPOSITION DU SIGNAL D'ENTREE EN COMPOSANTES TEMPORELLES POUR IDENTIFIER LES DIFFERENTS PROCESSUS SOUS-JASCENTS.</b> .....                     | <b>160</b> |
| 5.4.1.      | Décomposition multirésolution par filtrage passe-bande du signal de pluie .....  | 160        |
| 5.4.2.      | Architecture des modèles récurrents et non-récurrents prenant en compte les composantes temporelles à différentes échelles .....                     | 162        |
| 5.4.3.      | Exploitation des résultats .....   | 163        |
| 5.4.3.1.    | <i>Performances des modèles</i> .....  | 164        |
| 5.4.3.2.    | <i>Etude de la prise en compte des entrées par le modèle</i> .....   | 165        |
| 5.4.4.      | Conclusions sur la décomposition multiéchelle des pluies pour alimenter le modèle recurrent .....  | 167        |
| <b>5.5.</b> | <b>CONTRAINDRE LE MODELE POUR AMELIORER SES PERFORMANCES ET SA REPRESENTATIVITE</b> .....  | <b>168</b> |
| 5.5.1.      | Introduction .....   | 168        |
| 5.5.2.      | Article sur la modélisation hydrodynamique par apprentissage statistique contrainte par les informations extraites du corrélogramme croisé .....     | 168        |
| 5.5.3.      | Au-delà de l'article .....   | 175        |
| 5.5.3.1.    | <i>Conclusions sur les différents modèles</i> .....  | 175        |
| 5.5.3.2.    | <i>Analyse approfondie des contributions affectés aux pluies du modèle IANN</i> .....  | 177        |
| 5.5.4.      | Conclusions .....  | 178        |



|   |            |
|---|------------|
| <b>5.6. ANALYSE DE LA REPONSE IMPULSIONNELLE PAR APPRENTISSAGE STATISTIQUE .....</b>  | <b>178</b> |
| 5.6.1. Introduction .....   | 178        |
| 5.6.2. Etude de la <i>réponse impulsionnelle</i> de la relation pluie débit produite par les modèles récurrents ANN et IANN.....            | 179        |
| 5.6.2.1. Introduction .....   | 179        |
| 5.6.2.2. Application.....   | 179        |
| 5.6.2.3. Conclusions .....  | 181        |
| <b>5.7. VERS UNE CORRECTION DES DONNEES PAR LA « MODELISATION INVERSE » D'UN MODELE NON-LINEAIRE.....</b>                                   | <b>181</b> |
| 5.7.1. Introduction .....   | 181        |
| 5.7.2. Application.....   | 182        |
| 5.7.3. Conclusions sur l'assimilation de données .....  | 184        |
| <b>5.8. CONCLUSIONS GENERALES DU CHAPITRE .....</b>   | <b>185</b> |
| <b>CONCLUSION.....</b>  | <b>187</b> |
| <b>BIBLIOGRAPHIE.....</b>   | <b>189</b> |
| <b>ANNEXE A : COURBE DE TARAGE ETABIE SUR LE CYCLE 1962-1963 (D'APRES CONROUX, 2007) .....</b>  | <b>195</b> |
| <b>ANNEXE B : REPONSE IMPULSIONNELLE CALCULEE PAR CORRELATION CROISEE SUR L'ENSEMBLE D'ARRET (1959).....</b>                                | <b>196</b> |
| <b>ANNEXE C : RESUME DE LA CONTRIBUTION ORALE FAITE LORS DE LA 8EME CONFERENCE DE L'ASSOCIATION INTERNATIONALE DES GEOMORPHOLOGUES.....</b> | <b>197</b> |
| <b>ANNEXE D : RESUME DU POSTER PRESENTE LORS DE L'AGU FALL MEETING 2013 .....</b>   | <b>198</b> |
| <b>ANNEXE E : ENGLISH VERSION OF FIGURE 24 (P 133) .....</b>  | <b>199</b> |
| <b>RESUME .....</b>   | <b>202</b> |
| <b>ABSTRACT .....</b>   | <b>202</b> |

# TABLE DES FIGURES

|   |     |
|---|-----|
| Figure 1 : Cartes hydrologique et géologique du bassin versant de la Cèze. Modifié d'après Savary (2014). .....   | 20  |
| Figure 2 : Développement du réseau exondé de la Foux-de-Lauret (Hérault, France) associé à la présence d'une fracture (encadrée en tirets rouges). .....  | 21  |
| Figure 3 : Creusement polyphasé des karsts : ici reprise d'érosion dans les sédiments au fond de la rivière de la partie basse de la grotte de la Cocalière (Gard, France). .....   | 22  |
| Figure 4 : Lapiaz du Siebenhengste (Suisse). .....  | 23  |
| Figure 5 : Alimentation des karsts gravifiques, systèmes unaires et binaires. ....  | 25  |
| Figure 6 : Transfert réseau principal-réseau annexe à microporosité. ....   | 27  |
| Figure 7 : Transfert réseau principal-réseau annexe de cavités et de drains. La connectivité conditionne la vidange du réservoir annexe. ....   | 27  |
| Figure 8 : Injection de traceur à partir d'un réseau souterrain. ....   | 30  |
| Figure 9 : Galeries basses de la grotte de la Cocalière (Gard, France) : conduit appartenant à la zone épinoyée. ....   | 32  |
| Figure 10 : Schéma fonctionnel selon l'approche établie par Mangin (1975). ....   | 34  |
| Figure 11 : Représentation schématique de l'approche systémique. ....   | 35  |
| Figure 12 : Autocorrélation du signal de pluie enregistré à Valflaunès sur la période 1950-1967. ....   | 36  |
| Figure 13 : Corrélogramme croisé pluie-débit de l'hydrosystème karstique du Lez sur la période 1950-1967....  | 38  |
| Figure 14 : Description des filtres moyenne mobile unilatérale (MMU) et moyenne mobile unilatérale pondéré (MMUP) d'ordre $n=51$ jours. a) Séries de pluies brutes et filtrées ; b) Fonctions de transfert des filtres ; c) Poids relatifs affectés aux valeurs lors du calcul des séries filtrées. ....                                | 42  |
| Figure 15 : Représentation schématique de la décomposition multirésolution "Taverlette". Les différents cercles correspondent aux informations relatives à des bandes de fréquences données séparées au cours de la décomposition. Les rectangles en tirets correspondent aux ordres $n\alpha$ des filtres utilisés. ....               | 43  |
| Figure 16 : Cartes de localisation du Lez et de ses principaux affluents : Coulazou, Mosson et Lirou. Réalisée d'après les données Géoportail. ....   | 124 |
| Figure 17 : Températures mensuelles interannuelles enregistrées à la station de Montpellier-Fréjorgues sur la période 1961-1990. ....   | 124 |
| Figure 18 : Rue du village des Matelles. (a) pendant l'événement du 29/09/2014. (b) lors d'une accalmie pendant l'événement du 06/10/2014. ....   | 125 |
| Figure 19 : Lez au niveau de l'Hôtel de région dans sa partie aménagée lors de la crue du 29 septembre 2014. <i>Bogdan – Midi Libre</i> . ....  | 127 |
| Figure 20 : Observation des aménagements de la source du Lez asséchée par les pompages effectués en amont de la source (septembre 2013). ....   | 128 |
| Figure 21 : Log géologique et hydrogéologique schématique de l'aquifère du Lez d'après G. Marjolet et J. Salado (1976) et P. Bérard (1983). ....  | 129 |
| Figure 22 : Carte des isobathes de la surface d'érosion messinienne de la plate-forme du Golfe du Lion (Lofi, 2002, modifiée d'après Guennoc et al., 2000). Dans la vallée du Languedoc-Roussillon, le réseau détaillé des fleuves messiniens et de leurs affluents a été établi à partir des nouvelles données de la campagne LRM96. . | 131 |

|   |     |
|---|-----|
| Figure 23 : Coupe schématique générale du bassin du Lez. Kong A Siou (2011) modifié d'après M. Bonnet et M. Mattauer (2010).....  | 132 |
| Figure 24 : Bloc diagramme schématique du bassin de la source du Lez et de son fonctionnement hydrodynamique. Modifié d'après Paloc (1979). Version anglaise en Annexe E.....   | 135 |
| Figure 25 : Carte hydrogéologique interprétative des circulations souterraines de la source du Lez. ....  | 138 |
| Figure 26 : Valeurs médianes des cumuls de pluie mensuels sur la période 1950-1967. ....  | 146 |
| Figure 27 : Corrélogramme simple de la série de pluie journalière pour la période 1950-1967. a) $k \in [0;750]$ b) $k \in [0;50]$ . ....  | 148 |
| Figure 28 : Spectre simple du signal de pluie (échelles logarithmiques) pour la période 1950-1967. La courbe rouge correspond à la transformée de Fourier de l'autocorrélation ayant subi l'application d'une troncature de 1500 jours et la courbe noire correspond à la transformée de Fourier de l'autocorrélation ayant subi une troncature de 150 jours. ....  | 148 |
| Figure 29 : Moyennes sur la période 1950-1967 des descripteurs statistiques mensuels du débit. ....   | 150 |
| Figure 30 : Corrélogramme simple du signal de débit de la source du Lez sur la période 1950-1967.....   | 151 |
| Figure 31 : Densité spectrale ou spectre simple du signal de débit à la source du Lez (échelles logarithmiques) pour la période 1950-1967. La courbe rouge correspond à l'application d'une troncature de 1500 jours et la courbe noire correspond à une troncature de 150 jours.....   | 152 |
| Figure 32 : Densité spectrale ou spectre simple du signal de débit à la source du Lez pour la période 1950-1967. La courbe rouge correspond à l'application d'une troncature de 1500 jours et la courbe noire correspond à une troncature de 150 jours. ....  | 152 |
| Figure 33 : Coefficients d'aplatissement (kurtosis) et d'asymétrie (skewness) annuels des séries journalières de pluie (en bleu) et de débit (en rouge) pour la période 1950-1967. ....   | 154 |
| Figure 34 : Fonction de transfert, en échelles logarithmiques (a) et linéaires (b), de l'hydrosystème karstique du Lez sur la période 1950-1967. ....   | 154 |
| Figure 35 : Corrélogramme croisé pluie-débit (courbe noire) sur la période 1950-1967. Les courbes en pointillés correspondent aux processus sous-jacents supposés. ....   | 156 |
| Figure 36 : Illustration des performances, sur l'ensemble de test (1960-1961), du modèle sélectionné par validation croisée. a) Précipitations et hydrogrammes observé (en noir) et simulé (en rouge). b) Corrélogrammes croisés pluie/débit (observé et simulé). c) Fonctions de transfert pluie/débit (observé et simulé) en échelles logarithmiques pour une troncature 1500 jours. Les figures b) et c) ont été établies à partir des séries complètes (ensembles d'apprentissage, d'arrêt et de test)..... | 159 |
| Figure 37 : Séries (période 1950-1967) de pluie à Valflaunès (a) ; de débit à la source (g) ; et les composantes temporelles de pluie : (b) = 1 jour ; (c) = 2 jours ; (d) = 7 jours ; (e) = 19 jours ; (f) = 51 jours. Les plages de couleur (g) correspondent au découpage, pour la modélisation, des ensembles d'apprentissage (vert), d'arrêt (violet) et de test (bleu). ....  | 161 |
| Figure 38 : Signaux centrés réduits (adimensionnels) du débit observé et de la composante 51 jours (C51). ..  | 161 |
| Figure 39 : Fonctions de transfert pluie/composantes de pluie (en pointillés) et pluie/débit (en trait plein). ..   | 162 |
| Figure 40 : Représentation schématique de l'architecture du modèle par réseaux de neurones développé pour être alimenté par des composantes de pluie ( $C_1$ à $C_{51}$ ). Chaque fenêtre d'entrée exogène est reliée à un neurone linéaire qui est relié à la couche cachée, elle-même reliée au neurone de sortie. Les paramètres ( $w$ ) en rouges sont utilisés pour le calcul de la contribution totale de l'entrée $u_i$ . ....   | 162 |
| Figure 41 : Hydrogrammes observés et simulés par les deux modèles sur l'ensemble de test (1966-1967). ....  | 164 |

|  |     |
|--|-----|
| Figure 42 : Hydrogramme du débit mesuré et erreurs du modèle récurrent (en m <sup>3</sup> /s) et série d'ETP (ici sans dimension). .....   | 167 |
| Figure 43 : Représentation graphique des entrées exogènes de pluie (a), d'ETP (b) ; la sortie désirée (f) ; la sortie calculée aux itérations 4 (c), 5 (d) et 7 (e) sur la première partie de l'ensemble d'apprentissage (1951-1958) du modèle ANN. .... | 176 |
| Figure 44 : Comparaison des poids affectés aux entrées de pluies par les modèles ANN et IANN et le corrélogramme croisé pluie-débit.....   | 177 |
| Figure 45 : Étude des performances en validation croisée (a) et du nombre de paramètres (b) des modèles ANN et IANN.....   | 180 |
| Figure 46 : Comparaison des poids affectés par les modèles ANN et IANN avec le corrélogramme croisé. ....  | 181 |
| Figure 47 : (a) Illustration des débits mesurés et calculés avec et sans assimilation. (b) Illustration des pluies mesurées et modifiées par assimilation de données.....  | 183 |
| Figure 48 : Modifications positives (rouge) et négatives (bleu) apportées aux pluies par l'assimilation et identification d'une variabilité saisonnière (noir). ....   | 184 |



# LISTE DES TABLEAUX

|   |     |
|---|-----|
| Tableau 1 : Réactions de l'hydrosystème, en fonction de l'état initial, à deux événements aux cumuls proches. ....  | 126 |
| Tableau 2 : Corrélations croisées entre les données du pluviomètre de Valflaunès et les données issues de d'autres pluviomètres sur le bassin pour la période 1996-2005 (échantillonnage journalier). ....  | 145 |
| Tableau 3 : Principaux descripteurs statistiques de la série chronologique de pluie journalière (en mm) pour la période 1950 à 1967. Le cumul et le maximum correspondent à la moyenne des valeurs annuelles. ....  | 146 |
| Tableau 4 : Principaux descripteurs statistiques de la distribution annuelle des pluies journalières sur la période 1950-1967. ....   | 147 |
| Tableau 5 : Principaux indicateurs statistiques de la série chronologique de débit journalier (en m <sup>3</sup> /s) pour la période 1950 à 1967. La moyenne, la médiane, le minimum et le maximum correspondent aux moyennes des valeurs annuelles. .... | 149 |
| Tableau 6 : Principaux indicateurs statistiques de la distribution du débit annuel sur la période 1950-1967. ...  | 149 |
| Tableau 7 : Situation du Lez dans la classification des karsts. D'après Mangin, 1984. ....  | 153 |
| Tableau 8 : Périodicités identifiées à partir de pics observés sur la fonction de transfert de la période 1950-1967. ....   | 155 |
| Tableau 9 : Temps de transferts vers la source du Lez identifiés par traçages (référencés dans « projet Lez GMU »). ....  | 155 |
| Tableau 10 : Architecture, complexité et performances du modèle sélectionné par validation croisée. ....  | 158 |
| Tableau 11 : Taille des fenêtres temporelles, ordre et nombre de paramètres obtenus pour les modèles non-récurrent et récurrent. ....   | 163 |
| Tableau 12 : Scores de Nash moyens (100 initialisations) obtenus sur l'ensemble de test pour les modèles non-récurrent et récurrent. ....   | 164 |
| Tableau 13 : Contributions affectées aux variables d'entrée par les modèles récurrent et non-récurrent. ....  | 165 |
| Tableau 14 : Récapitulatif des principaux résultats obtenus avec différentes approches de modélisation. Le score de Nash est celui obtenu sur l'ensemble de test. ....  | 175 |
| Tableau 15 : Architecture des modèles ANN et IANN. ....   | 179 |
| Tableau 16 : Performances obtenues sur l'ensemble de test (1951-1952) pour le modèle statique avec et sans assimilation de données. ....  | 182 |



## RESUME

La connaissance du fonctionnement hydrodynamique des karsts représente un enjeu planétaire pour la ressource en eau car ils alimentent en eau potable près de 25% de la population mondiale. Néanmoins, la complexité, l'anisotropie, l'hétérogénéité, la non-linéarité et l'éventuelle non-stationnarité de ces aquifères en font des objets encore largement sous-exploités du fait de la difficulté de caractériser leur morphologie et leur fonctionnement hydrodynamique. Dans ce contexte, le paradigme systémique permet d'apporter de nouvelles méthodes en étudiant ces hydrosystèmes au travers de la relation entre leurs signaux d'entrée (pluie) et de sortie (débit).

La démarche proposée dans cette thèse consiste à utiliser un maximum d'informations, issues du terrain et des analyses systémiques, pour contraindre les modèles par réseaux de neurones. L'objectif est de les rendre interprétables en termes de processus hydrodynamiques en rapprochant le fonctionnement du modèle à celui du système naturel afin d'obtenir une bonne représentation et d'extraire des connaissances à partir des paramètres du modèle.

Ainsi ce travail porte sur l'association des informations disponibles sur l'hydrosystème avec les résultats des analyses corrélatoires et spectrales pour le développement d'une décomposition multirésolution temporelle ainsi que pour contraindre les modèles par réseaux de neurones. Une nouvelle méthode de sélection des variables, plus à même de représenter le fonctionnement hydrodynamique du système à long terme, a ainsi pu être proposée. Ces modèles contraints par l'information présentent de très bons résultats et offrent la possibilité, grâce à leurs paramètres, d'étudier la contribution temporelle des variables d'entrée à l'estimation de la sortie mesurée.

La modélisation des hydrosystèmes non-linéaires et non-stationnaires par réseaux de neurones a été enrichie par une implémentation originale de l'assimilation de données qui conduit à l'amélioration des performances. En effet, selon que les non-stationnarités concernent le bassin ou les forçages, l'assimilation a pu être respectivement utilisée pour modifier les paramètres ou les variables d'entrée des modèles.

La modification des variables d'entrées ouvre un champ d'application considérable puisque celle-ci peut être utilisée pour i) combler des lacunes ou encore homogénéiser des séries chronologiques, ii) estimer la pluie efficace.

Finalement, ces différentes méthodes d'analyse et de modélisation, essentiellement développées sur l'hydrosystème karstique du Lez, permettent d'améliorer la connaissance de la relation pluie-débit à différentes échelles temporelles. Ces outils méthodologiques offrent donc la perspective d'une meilleure gestion de l'aquifère tant en termes de crues que de ressource. L'avantage de ces outils d'analyse et de modélisation est qu'ils peuvent être transposés à d'autres systèmes.

## ABSTRACT

Improving knowledge of karst hydrodynamics represents a global challenge for water resources because karst aquifers provide approximately 25% of the world population in fresh water. Nevertheless, complexity, anisotropy, heterogeneity, non-linearity and possible non-stationarity of these aquifers make them underexploited objects due to the difficulty to characterize their morphology and hydrodynamics. In this context, the systemic paradigm proposes others methods by studying these hydrosystems through input-output (rainfall-runoff) relations.

The approach proposed in this thesis is to use information from field measurement and from systemic analyses to constrain neural network models. The goal is to make these models interpretable in terms of hydrodynamic processes by making model functioning to be similar to natural system in order to obtain a good representation and extract knowledge from model parameters.

This work covers the association of information available on the hydrosystem with correlation and spectral analyses to develop a temporal multiresolution decomposition of variables and to constrain neural network models. A new method for variable selection, adapted to represent long term hydrodynamics of the system, has been proposed. These constrained models show very good results and allow, through their parameters, to study the temporal contribution of inputs variables to the output.

Modeling nonlinear and non-stationary hydrosystems with neural network has been improved by a novel implementation of data assimilation. More precisely, when non-stationarity is attributed to the catchment, data assimilation is used to modify the model parameters. When the inputs are non-stationary, data assimilation can be used to modify the inputs.

The modification of inputs opens considerable scope to: i) fill gaps or homogenizing time series, ii) estimate effective rainfall.

Finally, these various analyses and modeling methods, mainly developed on the karst hydrosystem *Lez*, can improve the knowledge of the rainfall-runoff relationship at different time scales. These methodological tools thus offer perspectives of better management of the aquifer in terms of floods and resources. The advantage of these analyses and modeling tools is that they can be applicable to other systems.





# INTRODUCTION

Les hydrosystèmes karstiques sont très répandus à travers le monde. Ces entités géomorphologiques dont la genèse et le fonctionnement hydrodynamiques sont complexes ont toujours occupé une place considérable pour les civilisations évoluant à leur proximité. Utilisés par le passé comme abris et comme support d'expression, les karsts sont aujourd'hui très prisés pour des activités récréatives et scientifiques. Ces hydrosystèmes présentent aussi un enjeu majeur pour l'alimentation en eau potable de la population planétaire toujours croissante. Actuellement, près du quart de la population mondiale consomme de l'eau issue des karsts. Or, il apparaît que cette ressource est très largement sous exploitée. Cela s'explique par le fait que ces hydrosystèmes ont un développement souterrain au sein de roches fracturées et altérées qui rend leur caractérisation particulièrement ardue. De plus, les circulations d'eau s'effectuant dans des vides aux dimensions et à la connectivité extrêmement variables, ces hydrosystèmes n'ont généralement pas la capacité de filtrer les pollutions, ce qui peut les rendre très vulnérables.

Selon leur histoire géologique, tectonique et hydrodynamique, les karsts sont susceptibles d'effectuer le stockage temporaire de l'eau. Cette propriété est très intéressante pour des régions comme le pourtour méditerranéen où l'inégale répartition temporelle des pluies au cours de l'année génère une saison sèche extrêmement marquée et donc un stress hydrique intense au niveau des eaux de surface. Les régions méditerranéennes comme le Sud-Est de la France sont, de plus, soumises à d'intenses précipitations, essentiellement au printemps et à l'automne, qui sont responsables de dégâts matériels et humains considérables. Or, en sortie de saison sèche, l'état hydrique des karsts est généralement au plus bas et ces derniers sont susceptibles de jouer le rôle d'écrêteurs des premières crues d'automne. Il s'avère que l'exploitation de la ressource en eau des hydrosystèmes karstiques durant la période sèche tend à accentuer cet « effet tampon » en diminuant les réserves et libérant ainsi des vides qui seront autant de volumes disponibles pour l'écrêtage des crues.

Compte tenu des enjeux et des difficultés d'étude présentés, cette thèse s'inscrit dans une démarche d'étude et de modélisation du fonctionnement hydrodynamique des karsts au travers de la relation entre les forçages climatiques (essentiellement la pluie) et la sortie de l'hydrosystème (ici le débit). Elle a pour objectif de revisiter les méthodes de l'approche systémique avec des outils récents, les réseaux de neurones et l'analyse multirésolution temporelle, qui permettent d'aborder la non-linéarité et la non-stationnarité des objets naturels tels que les hydrosystèmes.

Le premier chapitre de cette thèse a pour objectif de présenter, dans un premier temps, la genèse, la morphologie et le fonctionnement hydrodynamique des karsts dits gravifiques. Cette présentation vise à souligner la complexité, l'hétérogénéité, la non-linéarité et la non-stationnarité du fonctionnement de ces hydrosystèmes et des forçages qui les affectent. Les verrous scientifiques identifiés conduisent, dans un second temps, à présenter les différents types d'approches utilisées pour caractériser et représenter le fonctionnement hydrodynamique des karsts. Ces diverses approches (naturalistes, conceptuelles, physiques, etc.) sont généralement limitées par la difficulté d'étudier et de caractériser de façon précise les propriétés physiques et les processus hydrodynamiques au sein des karsts.

Dans ce contexte, le chapitre 2 propose une alternative aux modélisations physiques par une approche globale fondée sur la relation entre les entrées et les sorties du système. Cette approche systémique abordée au travers des analyses corrélatoires et spectrales, qui sont destinées à l'étude des systèmes linéaires invariants, sera généralisée afin d'approfondir la connaissance des différents processus non-linéaires occurrents à des échelles temporelles variées.

Afin d'approfondir la compréhension et la modélisation du fonctionnement hydrodynamique des karsts, le chapitre 3 aborde l'utilisation d'une approche globale plus récente : les réseaux de neurones artificiels. Ces outils d'apprentissage statistique, et leur application à la modélisation hydrodynamique des karsts, sont présentés et décrits au travers d'un article paru dans la revue *Karstologia*. La seconde partie du chapitre 3 concerne l'utilisation des réseaux de neurones pour la modélisation hydrodynamique des hydrosystèmes soumis à des non-stationnarités, qu'elles soient dues à la modification du système ou de ses entrées. Cette partie est présentée au travers d'un article faisant suite à un workshop focalisé sur les non-stationnarités de différents hydrosystèmes qu'ils soient karstiques ou non. Dans cet article, deux méthodes : l'adaptativité et l'assimilation de données, réécrites dans le formalisme neuronal, sont utilisées pour respectivement corriger les paramètres et les entrées des modèles neuronaux.

Suite à la présentation des verrous scientifiques et des méthodes proposées pour répondre à notre objectif de revisiter les méthodes d'analyse systémique, le chapitre 4 apporte une description de l'hydrosystème choisi comme cas d'étude. Celui-ci est l'hydrosystème karstique du Lez qui est exploité pour l'alimentation en eau potable de la ville de Montpellier.

Enfin, le chapitre 5 porte sur l'application des méthodes proposées aux chapitres 2 et 3 à l'hydrosystème du Lez. Les résultats obtenus soulignent l'importance de la prise en compte des processus hydrodynamiques à différentes échelles temporelles pour estimer la réserve, mais aussi pour appréhender les conditions initiales du système qui ont un impact sur les premières crues automnales. Les outils ainsi développés et appliqués à l'hydrosystème karstique du Lez ouvrent de nombreuses perspectives pour l'étude des systèmes naturels au fonctionnement complexe, non-linéaire et non-stationnaire. L'autre ouverture majeure de ce travail est le prétraitement et la correction des signaux qui vise à répondre aux besoins croissants de séries chronologiques longues, homogènes et sans lacunes pour l'étude du changement climatique.

# 1. LES HYDROSYSTEMES KARSTIQUES

En tant qu'entités géomorphologiques et hydrologiques, les karsts sont des éléments clés pour certaines civilisations. Leur rôle peut varier selon les régions et les époques : du terrain d'aventure à l'habitat en passant par la ressources (eau, hydrocarbures). Il occupe souvent une place importante pour l'homme qui lui voue, au travers de nombreuses approches (naturaliste, conceptuelle, physique...), un intérêt particulier.

Actuellement, les hydrosystèmes karstiques font l'objet d'études car ils comportent une ressource en eau considérable encore très largement sous-exploitée. Cette sous-exploitation est vraisemblablement due autant à la « mauvaise » réputation de ces systèmes en relation avec leur incapacité à filtrer l'eau, qu'à leur complexité, ainsi qu'à la difficulté de les étudier et donc à leur méconnaissance.

Pour mieux comprendre l'intérêt de ces aquifères et la difficulté de leur étude, ce chapitre aborde dans un premier temps la définition historique du karst, associée à sa morphologie, pour ensuite introduire l'importance du couplage entre la morphologie souterraine et les écoulements qui s'y déroulent. Les processus menant à la karstification sont présentés afin de mettre en évidence les obstacles à la compréhension de ces aquifères : l'anisotropie et l'hétérogénéité de l'objet physique étudié, ainsi que la non-linéarité et la superposition de plusieurs dynamiques d'écoulements à différentes échelles de temps. Ces notions nous permettront d'introduire le terme d'hydrosystème karstique, qui nous paraît le plus approprié pour dénommer ces systèmes complexes dans le cadre de ces travaux.

Dans un deuxième temps, des méthodes de représentation conceptuelle et fonctionnelle des hydrosystèmes karstiques sont présentées. Les fonctions d'infiltration, de transfert et de stockage sont présentées et permettent d'expliquer la complexité de la réponse hydrodynamique de ces hydrosystèmes.

Enfin, les méthodes d'études et de caractérisation du fonctionnement hydrodynamique sont abordées afin de mettre en lumière les difficultés et les limites des modélisations de ces systèmes, tellement mal connus, bien que parfois très étudiés.

## 1.1. LE KARST : DEFINITIONS

### 1.1.1. PREMIERES DEFINITIONS HISTORIQUES : MORPHOLOGIE KARSTIQUE

La morphologie du karst se caractérise en premier lieu par la quasi absence de réseau hydrographique comme l'illustre la Figure 1 sur le cas particulier du plateau calcaire de Méjeannes-le-Clap (Gard, FRANCE). On voit en effet que ce plateau karstique ne présente aucun réseau hydrologique de surface alors qu'il existe de nombreuses morphologies épikarstiques (Jolivet et Martin, 2008), et que des circulations souterraines ont été mises en évidence (Jolivet, 2011). On peut parfois noter la présence de quelques cours d'eau allogènes, mais leur écoulement est souvent perturbé et donne une impression anarchique : débit aval inférieur au débit amont, comme pour la rivière Cèze (Gard, FRANCE) soumise à des pertes qui exsurgent à l'aval de son propre cours d'eau. L'absence de circulations de surface donne lieu à des formations spécifiques comme par exemple les dolines et lapiaz, respectivement dépressions fermées ou cannelures d'érosion de surface. Les premières approches, purement descriptives des formes observées, se sont enrichies dans les années 70 (Bakalowicz, 1975 ; Drogue, 1971 ; Mangin, 1974) permettant d'aboutir à une définition moderne (Ford et Williams, 1989) qui définit le karst comme un ensemble de formes de surfaces, de formes souterraines et de conditions d'écoulements. Ainsi les formes et les écoulements sont étroitement liés et ne peuvent être complètement dissociés dans l'étude du karst. On distingue classiquement trois types de karst : i) les karsts gravifiques (Mangin, 1982) formés par l'association des eaux météoriques et d'un gradient hydraulique ; ii) les karsts littoraux (Fleury, 2005) qui résultent de l'association entre les mouvements marins (marée, vague...) et le

mélange entre les eaux douces et salées, iii) les karst hypogènes associés à des remontées de fluides thermaux ou minéralisés. Nous nous intéresserons dans ce mémoire exclusivement aux karsts gravifiques.

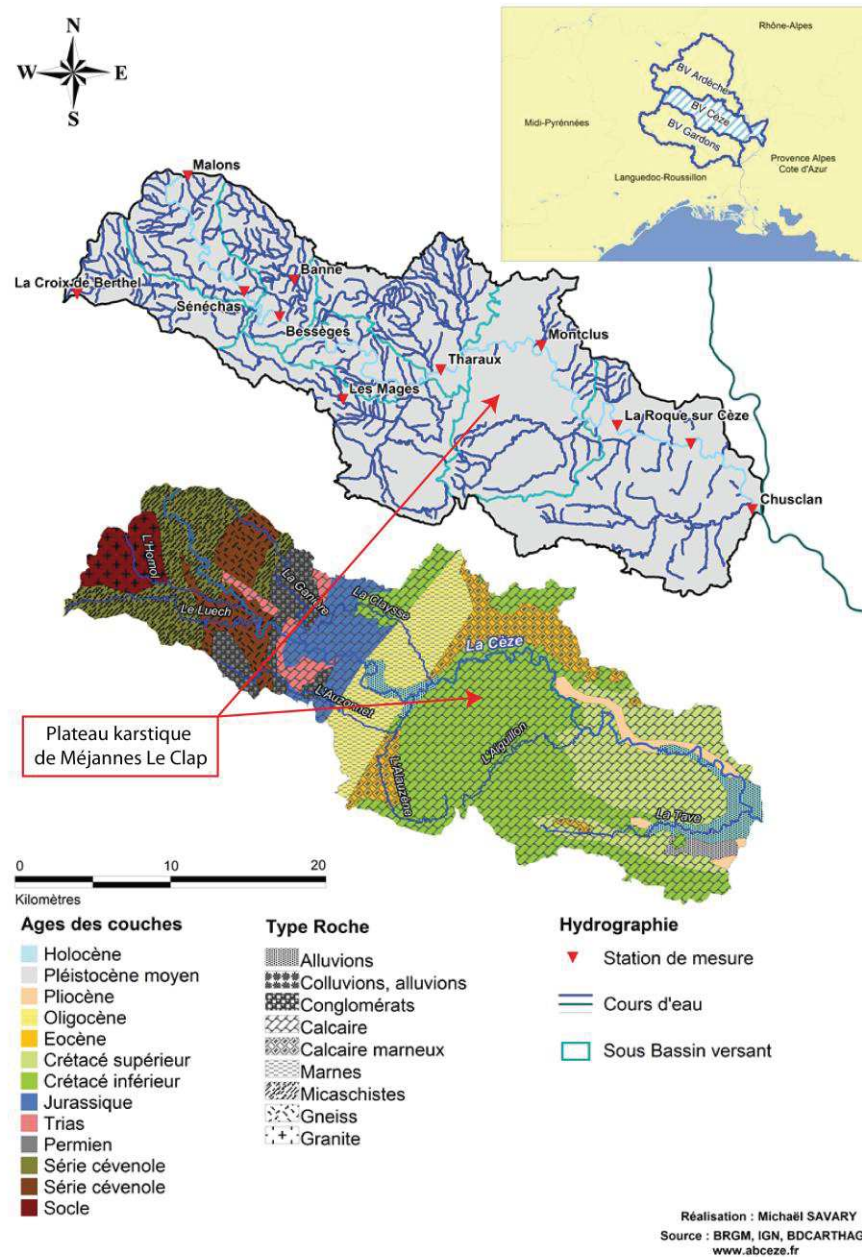


Figure 1 : Cartes hydrologique et géologique du bassin versant de la Cèze. Modifié d'après Savary (2014).

### 1.1.2. PROCESSUS DE KARSTIFICATION

La karstification est un processus hétérogène, anisotrope et généralement polyphasé. Ce processus produit une altération physicochimique d'une roche mère selon des zones de faiblesse (Bakalowicz, 2005) conduisant à la formation de vides karstiques, par essence hétérogène, mais organisés et connectés selon un ou plusieurs axes de drainage. La karstification peut être vue comme la réaction entre un substrat (entité géologique carbonatée fracturée) et un réactif (fluide agressif, l'eau météorique acidifiée par la matière organique) avec un apport d'énergie (gradient hydraulique).

Le développement d'un karst est donc conditionné par le substrat, généralement des roches carbonatées. La matrice (souvent une roche calcaire) est *a priori* imperméable, mais une fois affectée par des mouvements tectoniques, cette roche devient perméable du fait de l'existence de failles et de fractures (Figure 2).



**Figure 2 : Développement du réseau exondé de la Foux-de-Lauret (Hérault, France) associé à la présence d'une fracture (encadrée en tirets rouges).**

Le substrat (roche mère) présente donc une porosité très variable selon l'échelle spatiale considérée, avec des tailles de vides allant du micromètre à plusieurs dizaines de mètres. En ce qui concerne la perméabilité, si l'on définit une perméabilité estimée à différentes échelles spatiales, il est possible de tracer une relation entre cette perméabilité, à une échelle donnée, et l'échelle spatiale considérée. Il a ainsi été montré qu'une relation de type fractale pouvait être mise en évidence dans les karsts (Mangin, 1994). Outre son intérêt propre, cette observation suggère qu'un phénomène global, auto-organisé, intervient dans la karstification.

L'énergie indispensable à la dissolution du karst en profondeur est le gradient hydraulique qui est conditionné par le potentiel altimétrique entre la zone d'alimentation et l'exutoire du karst. Ce potentiel est directement lié au niveau de base qui est susceptible de varier en fonction des épisodes tectoniques (e.g. surrection, ...), des variations eustatiques (cas du bassin méditerranéen avec la crise messinienne ; Audra et *al.*, 2004), ou des conditions climatiques (glaciations, ...).

L'énergie apportée par le gradient hydraulique entraîne les eaux météoriques, rendues agressives par l'enrichissement en CO<sub>2</sub>, jusqu'en profondeur. Ces eaux empruntent les conduits les plus perméables et favorisent l'augmentation du volume des vides par dissolution. Le processus de karstification a donc pour effet d'augmenter l'hétérogénéité et le volume des vides du milieu.

La karstification affecte donc un substrat hétérogène dont la distribution des vides (pores de la matrice, fracturation...) est anisotrope. Ainsi, le processus de dissolution s'effectue selon des directions qui dépendent de la perméabilité, du gradient hydraulique et de la lithologie.

La genèse et l'évolution du karst sont des processus rapides à l'échelle des temps géologiques, de l'ordre de la dizaine ou la centaine de milliers d'années selon le contexte, avec parfois des évolutions très rapides selon l'échelle d'observation (variations climatiques, éboulements, activité anthropique, etc.) (Salomon, 1999). Les évolutions rapides sont susceptibles de perturber le fonctionnement hydrodynamique du système et

d'engendrer des non-stationnarités observables à l'échelle humaine. Qui plus est, sa formation au cours des temps géologique est polyphasée : un karst à maturité peut se voir colmaté au cours d'une période moins favorable au creusement (réhausse du niveau de base, diminution du régime pluviométrique, ...), puis à nouveau recréusé, et ce, selon plusieurs phases successives comme l'illustre la Figure 3 dans la grotte de la Cocalière (Gard, France). Ces différents processus amènent donc le système karstique à une situation extrêmement intriquée et difficile à analyser en l'absence de connaissance exhaustive sur les vides existants, leur éventuel comblement et les circulations qui y transitent, ainsi que sur l'histoire géologique et climatique du site considéré. Le karst est donc un milieu fortement hétérogène et anisotrope qui, soumis à des conditions de forçages non-stationnaires, est susceptible d'évoluer rapidement.



Figure 3 : Creusement polyphasé des karsts : ici reprise d'érosion dans les sédiments au fond de la rivière de la partie basse de la grotte de la Cocalière (Gard, France).

## 1.2. REPRESENTATIONS CONCEPTUELLES DU KARST

Plusieurs représentations conceptuelles du karst peuvent co-exister qui découlent de la double description du karst comme objet physique et comme « réservoir » parcouru par des écoulements. L'objet physique est décrit par sa lithologie, d'un point de vue géochimique, mais aussi géométrique (joints de stratification, succession des différents niveaux), ainsi que par l'histoire tectonique régionale et ses conséquences (plissement, fracturation, contacts anormaux). L'objet « réservoir » est décrit en relation avec l'écoulement de l'eau au sein de ce réservoir. Par exemple, l'organisation verticale du karst témoigne d'une convergence des écoulements vers des drains de tailles plus importantes en fonction de la maturité du karst (Klimchouk, 2004).

En fonction des objectifs fixés, on peut distinguer, de façon non exhaustive plusieurs représentations conceptuelles du karst:

1. L'étude géomorphologique du karst peut s'effectuer en distinguant l'exokarst, qui correspond aux morphologies de surface (dolines, lapiaz, aven...), et l'endokarst qui concerne la partie souterraine, noyée ou non, avec des cavités ou des éléments témoignant de l'activité hydrodynamique actuelle (rivières souterraines, siphons...) ou passée (réseau exondé, remplissage, spéléothèmes,...). Cette approche essentiellement adaptée au karst en tant qu'objet physique, même si elle est essentielle comme connaissance préliminaire, ne satisfait pas complètement nos attentes qui sont portées sur l'étude du fonctionnement hydrodynamique.
2. Une des représentations conceptuelles du karst comme encaissant « réservoir » consiste à distinguer trois entités majeures au sein du karst : i) l'épikarst (lorsqu'il est présent), ii) la zone non-saturée (ZNS), iii) la zone saturée (ZS).

**L'épikarst** est la partie superficielle du karst, dont l'épaisseur peut varier de quelques mètres à plusieurs dizaines de mètres (Mangin, 1975 ; Klimchouk, 2004). Il est le siège d'une importante dissolution qui conduit

généralement à une très forte porosité de l'ordre de 5% à 10%. On peut observer des morphologies épikarstiques spectaculaires telles que le lapiaz (Figure 4).



Figure 4 : Lapiaz du Siebenhengste (Suisse).

L'épikarst est la zone d'interface entre la surface et la partie souterraine. C'est la partie du karst qui a pour fonction de transférer les eaux de surfaces vers le réseau souterrain, avec dans certains cas un stockage qui peut s'avérer considérable, on pourra alors parfois parler de nappe perchée.

**La zone non-saturée** est le siège du transfert de l'eau depuis la zone superficielle vers la zone saturée. Le transfert est assuré par un réseau de drains et de fissures d'une variabilité dimensionnelle considérable allant du micromètre à plusieurs dizaines de mètres. Cette hétérogénéité des vides karstiques témoigne de différents types d'écoulements qui seront décrits par la suite. Ces transferts peuvent s'effectuer de manière diphasique (eau-air).

**La zone saturée** est noyée, elle peut avoir une organisation plus prononcée des conduits selon l'axe de drainage. Elle est le siège du transfert vers le ou les exutoires à travers des « drains », dont certains peuvent avoir une section importante (plusieurs dizaines de m<sup>2</sup>). La zone saturée peut avoir une géométrie complexe du fait du caractère polyphasé de la karstification. C'est le cas des karsts de type vauclusien qui présentent un développement profond du réseau qui témoigne d'une remontée importante du niveau de base.

3. Une approche conceptuelle plus fine consiste à distinguer 4 ensembles (Camus, 2003) associés à la dynamique de l'hydrosystème : épikarst, zone d'infiltration, zone épinoyée (domaine de variation hautes eaux/basses eaux), zone noyée. La prise en compte de la zone de battement du niveau piézométrique est un paramètre déterminant pour l'étude du processus de karstification et donc de l'évolution du réseau.

Un autre point important réside dans la conceptualisation des « réservoirs ». En effet, comme nous le verrons par la suite, il est possible d'approcher le fonctionnement du karst en considérant un réseau principal de drainage et des réservoirs : des systèmes annexes. Or, étant donné le peu de connaissance sur la géométrie et la répartition de ces systèmes, il est préférable d'être en mesure d'en approcher les propriétés hydrodynamiques. Pour ce faire, on peut considérer que les fonctions de stockage et de transfert peuvent être assurées par des types de « réservoirs » très différents. On peut en effet distinguer, de façon non-exhaustive, des réservoirs constitués : i) de micropores (porosité de la matrice, micro-fractures...) plus ou moins interconnectés, ii) de cavités plus matures dont les volumes ont une taille plus conséquente. Les capacités de stockage et de transfert des différents réservoirs dépendent de leur extension spatiale et de leur connectivité au réseau de drainage.

Le fonctionnement des 3 entités géomorphologiques majeures du karst (épikarst, zones saturée et non-saturée) ainsi que celui des différents types de réservoirs (systèmes annexes) est développé dans la section suivante.



### 1.3. REPRESENTATION FONCTIONNELLE DU KARST

La représentation fonctionnelle du karst va être définie en référence avec les transferts de l'eau en son sein. Le karst apparaît ainsi non plus comme un seul objet géologique ou morphologique mais comme un milieu organisé en plusieurs zones, ou plus généralement en plusieurs compartiments, qui s'échange de la matière (eau, transfert solide). Le karst est donc vu comme un système, c'est-à-dire un ensemble d'éléments échangeant des flux (matière, énergie, information). Nous parlerons alors d'hydrosystème karstique ou plus simplement d'hydrosystème pour ne pas alourdir notre discours.

En fonction des flux qui nous intéressent à l'intérieur du système nous représenterons les fonctionnalités du karst selon plusieurs angles : les transferts de pression seront décrits par l'approche hydrodynamique. Les transferts de masse et les transferts solides sont abordés selon d'autres approches ; ils ne sont pas l'objet de ce manuscrit, même s'ils sont liés aux précédents.

La vision hydrodynamique du karst permet d'expliquer les morphologies évoquées précédemment, et aussi leur rapidité d'évolution. En effet, le moteur du processus de karstification est le gradient hydraulique qui domine les écoulements dans les différents compartiments du karst de la surface vers l'exutoire. À l'échelle de ces compartiments il existe différents types d'écoulement avec des dynamiques temporelles très variées. Si l'on s'attache à décrire chacun de ces écoulements et que l'on s'intéresse à l'aquifère karstique dans son ensemble, la complexité de la description devient très rapidement non maîtrisable. Pour cette raison la description hydrodynamique est souvent faite en considérant que l'hydrosystème karstique remplit, de façon générale, deux fonctions essentielles : le stockage et le transfert. Ces deux fonctions sont susceptibles d'interagir selon l'état hydrique du karst, comme nous le verrons par la suite. Les processus de transfert et de stockage étant intimement liés à la morphologie, à la géologie et au climat, ils sont susceptibles de varier dans le temps et bien entendu en fonction des hydrosystèmes étudiés. La présentation de ces processus restera donc assez générique afin de pouvoir aborder les différentes composantes hydrodynamiques des systèmes karstiques gravifiques. Néanmoins on pourra noter que les transferts de pression liés à l'eau dans le karst ne sont jamais dissociés du karst vu comme objet physique. Pour ces raisons, la présentation conceptuelle en trois zones : épikarst, zone saturée, zone non saturée nous paraît la plus adaptée ; c'est cette représentation que nous adoptons dans la suite.

#### 1.3.1. ENTREE DE L'HYDROSYSTEME : ALIMENTATION DE L'AQUIFERE

L'alimentation en eau de l'hydrosystème karstique est un élément essentiel tant pour sa formation que pour son fonctionnement. Elle peut provenir de deux origines différentes : i) l'alimentation par les pertes des rivières dite allochtone, ii) l'alimentation par les eaux météoriques.

##### **Alimentation par des pertes**

Un cours d'eau allochtone, dont le bassin versant peut être disjoint de la zone de recharge du karst, est susceptible d'alimenter le système souterrain par le biais de pertes. Les pertes sont synonymes d'une karstification généralement prononcée et donc une infiltration souvent rapide (Palmer, 2003). Ainsi, les zones de pertes peuvent correspondre à des vides de dimensions conséquentes avec des composantes verticales considérables qui peuvent atteindre des profondeurs de l'ordre de plusieurs dizaines de mètres.

L'alimentation de l'hydrosystème karstique par des pertes, qui de plus peuvent être diffuses, ajoute la complexité de la dynamique du cours d'eau de surface à celle du karst. L'alimentation de l'hydrosystème karstique par des pertes dépend rarement des conditions aval du cours d'eau souterrain, mais elle multiplie les dynamiques différentes (eau de surface et différents processus souterrains). La présence de ce type d'alimentation couplée avec les précipitations sur la zone de recharge confère au karst un caractère binaire (Mangin, 1978) comme l'illustre la Figure 5.




Figure 5 : Alimention des karsts gravifiques, systèmes unaires et binaires.

### Alimentation par les eaux météoriques

L'alimentation uniquement par les eaux météoriques confère un caractère unaire (Figure 5) au karst, elle est directement liée au climat et au type de précipitation. Le type de précipitation conditionne les écoulements et le stockage en fonction de leur répartition temporelle, spatiale et surtout de leur intensité. Les conditions de transfert de ces eaux météoriques au sein de l'hydrosystème karstique sont décrites dans les sections ci-après. La première phase concerne l'infiltration qui peut s'effectuer i) rapidement par concentration vers une zone « ouverte » du système, c'est-à-dire un conduit généralement vertical connecté au réseau de drainage, ii) de façon généralement plus lente et moins bien connue au travers de l'épikarst. Globalement, l'épikarst va représenter, avec ses nombreuses définitions (Klimchouk, 2004) qui dépendent des objectifs d'études, un objet mal connu dont les processus de fonctionnement et le rôle déterminant pour le fonctionnement général de l'hydrosystème restent des domaines d'étude encore dynamiques.

### 1.3.2. INFILTRATION ET TRANSFERT VERS LA ZONE SATURÉE

#### Transfert au sein de l'épikarst

La zone superficielle du karst est une zone qui peut effectuer plusieurs fonctions comme : i) le stockage temporaire (aquifère épikarstique), ii) le transfert vers la zone non-saturée.

Le stockage temporaire peut entraîner une perte par évaporation, ou encore, une alimentation retardée dans le temps (effet tampon), ce qui rend difficile l'interprétation de l'hydrogramme à l'exutoire (Lastennet & Mudry, 1997; Marsaud, 1997). La forte distribution des vides au sein de l'épikarst et leur convergence vers des conduits de collecte permet d'assurer une redistribution des eaux météoriques dans le temps. Les capacités de transfert et de stockage au sein de l'épikarst sont dominées par son état de maturité et de remplissage (Klimchouk, 2004), ces dernières étant mal connues. Klimchouk (2004) propose une représentation de l'évolution des propriétés intrinsèques et hydrodynamiques de l'épikarst en fonction de sa maturité et de son état de couverture.

#### Transfert dans la zone non-saturée

La variabilité importante des vides et leurs différents niveaux de connectivité au sein de la zone non-saturée sont responsables de deux types d'écoulements (Mangin, 1975): i) l'écoulement monophasique, ii) l'écoulement diphasique.

L'écoulement monophasique correspond aux écoulements dans des vides macroscopiques (supérieurs au centimètre), l'écoulement de l'eau se fait sous forme liquide, comme un ruissellement, qu'il soit vertical ou

pseudo-horizontale. Cet écoulement peut s'effectuer en présence d'air, mais ce dernier n'affecte pas les écoulements de manière prépondérante.

L'écoulement diphasique correspond à l'écoulement simultané d'air (chargé en vapeur) et d'eau. Il intervient dans les vides microscopiques (inférieur au millimètre). Ces vides peuvent correspondre à la porosité de la matrice, à la micro-fracturation du milieu. L'écoulement dans le réseau de fissures dépend des proportions respectives des deux phases induisant une concurrence entre les deux potentiels : potentiel lié à la gravité et celui lié à la capillarité.

Le fonctionnement de la zone non saturée est difficile à décrire du fait de la diversité des conditions qui s'y trouvent réunies. De plus, les fluctuations rapides et saisonnières du niveau piézométrique affectent l'extension de la zone non-saturée ce qui justifie, si on cherche à étudier les processus de transfert dans le détail, l'ajout de la zone épinoyée au schéma conceptuel du karst.

Grace au réseau de fissures et de vides associés, la zone non-saturée comporte des réserves considérables (Lastennet & Mudry, 1997), les écoulements diphasiques y induisent également un effet de seuil dans l'infiltration. La zone non-saturée est aussi une zone privilégiée pour l'acquisition d'une signature chimique comme l'attestent les travaux menés au Laboratoire Souterrain à Bas Bruit (Garry, 2007 ; Barbel-Perineau, 2013).

### 1.3.3. TRANSFERTS DANS LA ZONE SATURÉE

#### 1.3.3.1. RESEAU DE DRAINAGE PRINCIPAL

De façon générale, le transfert vers l'exutoire s'organise dans la zone saturée selon un axe de drainage dont le développement et l'organisation des vides témoignent de la dynamique d'un écoulement structuré, hiérarchisé. Ces transferts, sont souvent considérés comme sub-horizontaux, par opposition aux transferts verticaux de la zone d'infiltration. Ces écoulements vont être le vecteur de propagation de l'onde de crue. L'alimentation, parfois différée, du réseau de drainage principal s'effectue à différentes échelles temporelles et spatiales (locales, régionales). Le réseau de drainage principal effectue des échanges avec les vides karstiques connectés qui ont été définis comme des « systèmes annexes » au drainage par Mangin (1975).

#### 1.3.3.2. « SYSTEMES ANNEXES » AU DRAINAGE

Une partie de la complexité des hydrosystèmes karstique réside dans l'hétérogénéité des vides et leur distribution. À l'échelle locale, on peut distinguer différents types de porosité, l'une constituée par les drains, les vides macroscopiques qui assurent le transfert rapide, et également une partie du stockage ; et les autres liés à la porosité matricielle et aux microfissures. De façon générale, il existe d'importants échanges entre les différents types de vides karstiques. Ces échanges sont conditionnés par la direction du gradient hydraulique et la connectivité. Nous aborderons les échanges entre les systèmes annexes et l'axe de drainage principal en fonction du type de vide karstiques considérés.

##### 1.3.3.2.1. INTERACTION DRAIN-ZONES A FAIBLE POROSITE

L'axe principal du drainage est une zone en interaction avec des zones de faible porosité (porosité matricielle, réseau fissural), ces échanges sont conditionnés par la connectivité des vides karstiques avec le réseau principal et par l'orientation du gradient hydraulique. C'est-à-dire, idéalement si l'on ne considère pas les pertes de charges hydrauliques, que lorsque le niveau dans le drain principal est supérieur au niveau dans les zones de faibles porosités, les vides karstiques vont se remplir et donc effectuer une fonction de stockage (Figure 6).

Lorsque le gradient s'inverse et que le niveau dans le drain principal devient inférieur à celui de la zone peu perméable, le système annexe va déstocker progressivement et alimenter le débit de base de l'hydrosystème

(Figure 6). Le rapport entre les perméabilités des différents milieux contrôle ce gradient et donc le niveau dans la matrice, les fractures et les drains.




Figure 6 : Transfert réseau principal-réseau annexe à microporosité.

Ces systèmes annexes au drainage, dont la porosité et la perméabilité sont faibles, présentent donc une capacité de réserve qui peut s'avérer considérable et nécessaire à l'alimentation du débit de base de certaines sources karstiques en période sèche.

#### 1.3.3.2.2. INTERACTIONS DRAIN PRINCIPAL-CAVITES ANNEXES

Le caractère anisotrope et polyphasé de la karstification explique la présence de cavités aux dimensions variables et plus ou moins connectées avec l'axe de drainage principal. La maturité du karst et le développement des connexions entre ces systèmes annexes et le drain principal conditionnent les échanges sous l'impulsion du gradient hydraulique, comme l'illustre la Figure 7. Le transfert à partir des cavités annexes peut donc se faire de façon lente si la connectivité est faible, ou rapide lorsque le réseau est suffisamment mature pour assurer une bonne connexion. Une faible perméabilité engendre une restitution différée du volume d'eau stocké par les cavités annexes et donc une contribution à plus long terme (Figure 7). Dans le cas contraire le transfert se fera rapidement engendrant ainsi des composantes temporelles à court terme et se traduira par un stockage plus bref.




Figure 7 : Transfert réseau principal-réseau annexe de cavités et de drains. La connectivité conditionne la vidange du réservoir annexe.

Finalement, les systèmes annexes au drainage, sans préjuger de la taille des vides, ont un rôle important à jouer pour le fonctionnement de la zone saturée en absorbant une partie de l'onde de recharge qui va être restituée avec un retard plus ou moins prononcé en fonction du réseau étudié et des différents systèmes annexes.

#### 1.3.4. CONNECTIVITE REGIONALE ET EFFETS SEUIL

À l'échelle régionale, la connectivité des différentes entités de l'hydrosystème et l'équilibre des charges hydrauliques sont à l'origine d'effets de seuil. En effet, lorsque le niveau piézométrique de l'aquifère s'élève, il peut parfois alimenter des exutoires temporaires qui vont donc constituer un déficit en eau pour le bilan hydrique du système estimé à l'exutoire principal. Ces exutoires temporaires peuvent prendre la forme de « bouldous » lorsque l'aquifère est sous pression et participer aux crues de surface.

La pression dans l'aquifère est conditionnée par le niveau piézométrique et le caractère, soit totalement, soit localement : i) libre, ou, ii) captif. Ce caractère libre ou captif a une incidence sur l'alimentation, qui est plus localisée si l'aquifère est captif, et variable (localisée et diffuse) en fonction de l'épikarst lorsque l'aquifère est libre. Il y aura aussi une incidence sur les écoulements avec une mise sous pression importante qui peut générer des puits artésiens au niveau des zones captives, en zone libre le développement du réseau peut conduire à l'émergence de sources karstiques temporaires ou encore à des interactions avec des cours d'eau temporaires associés au ruissellement de surface et au débordement de la nappe.

Étant donné l'hétérogénéité des hydrosystèmes karstiques, le caractère libre ou captif peut se retrouver dans différents compartiments de l'aquifère, comme nous le présenterons dans le cas de l'hydrosystème karstique du Lez.

Les interactions à l'échelle régionale et les processus associés augmentent la non-linéarité et la non-stationnarité de la relation entrée-sortie de l'hydrosystème.

#### 1.3.5. PERTURBATIONS NATURELLES ET ANTHROPIQUES DU FONCTIONNEMENT DE L'AQUIFERE

De nombreuses perturbations peuvent affecter l'état de l'aquifère. Ces perturbations peuvent avoir une origine : i) naturelle (évapotranspiration, marées terrestres, etc.), ii) anthropique (barrages, pompes, etc.). Ces perturbations peuvent se manifester sous forme aléatoire, périodique ou encore contrôlée selon leur nature.

Ces différents types de perturbations sont susceptibles d'engendrer une modification des écoulements à des échelles temporelles très variées. En effet, un pompage dans l'aquifère est périodique en fonction de la demande, souvent journalière, tandis que l'évapotranspiration a une pseudo-période ajustée, en moyenne, sur le cycle annuel de la rotation de la Terre.

Les perturbations qui affectent l'hydrosystème correspondent à une variation des forçages en entrée du système, ou du système lui-même, ce qui complexifie encore l'étude de la relation entrées-sortie.

#### 1.3.6. ECHELLES TEMPORELLES DE L'HYDRODYNAMIQUE KARSTIQUE

L'hétérogénéité du réseau karstique ainsi que les forçages météorologiques, hydrologiques ou anthropiques induisent des écoulements au sein de l'aquifère karstique difficiles à analyser et à comprendre. Ces systèmes sont tout autant susceptibles de propager l'onde de crue, ce qui correspond à des processus à court terme, que de réaliser un stockage très important sur plusieurs cycles annuels. Ainsi, la présence de sources karstiques pérennes, sur le pourtour méditerranéen, témoigne du stockage effectué par les hydrosystèmes karstiques alimentant ces sources.

Ainsi, nous analysons le fonctionnement hydrodynamique du karst comme la résultante de : i) sa non-linéarité intrinsèque, ii) la diversité des échelles temporelles des processus de transfert, iii) la non-stationnarité du système et des forçages en entrée.

## 1.4. APPROCHES ET METHODES DE CARACTERISATION, DE COMPREHENSION ET DE REPRESENTATION DU FONCTIONNEMENT HYDRODYNAMIQUE DU KARST

Les karsts, dans les régions où ils existent, sont au cœur des préoccupations humaines. Les hommes du paléolithique et néolithique y ont trouvé de l'eau et un refuge, ainsi qu'un support d'expression de leurs liens métaphysiques avec la nature. L'homme moderne y trouve encore refuge en cas de conflit, il y pompe l'eau dont il a besoin, les sollicite à des fins récréatives ou spirituelle et y retrouve un bénéfice important pour sa qualité de vie. Il en résulte une multitude d'approches qui expliquent le niveau de connaissance actuel et son amélioration constante. De façon générale, l'objectif de ces investigations est de comprendre l'organisation et le fonctionnement de l'hydrosystème karstique par le biais de : i) l'observation, ii) la conceptualisation, iii) la modélisation. Cette section a pour objectif de souligner l'intérêt et la complémentarité des approches d'étude et de représentation du karst au travers d'une succession logique allant de l'observation et l'acquisition de données *in situ* (mesures des propriétés hydrodynamiques, acquisition des signaux caractéristiques : débit, piézométrie) à la conceptualisation et pour finir par la modélisation.

### 1.4.1. OBSERVATION

L'exploration spéléologique qui fournit des relevés de densité de fractures, d'ouverture des vides et les plans des réseaux souterrains, est une source précieuse de connaissance pour la description de l'objet physique que représente le système karstique. Avec l'amélioration technique des dernières décennies, il est désormais possible d'effectuer une cartographie 3D des réseaux explorables par l'homme (Sadier, 2014) qui se situent généralement dans la zone non saturée. Néanmoins, les plongées effectuées dans les réseaux noyés de la zone saturée ont aussi profité des avancées technologiques ; ainsi une plongée réalisée par Xavier Méniscus dans le réseau karstique de Font Estramar a permis de relever le plan de la source jusqu'à 248 mètres de profondeur, sans pour autant avoir atteint le fond du siphon. Des travaux de cartographie du réseau de drainage et d'enregistrements physiques sur les écoulements (pression, température, ...) de la zone saturée grâce à l'utilisation de sondes mobiles miniaturisées (semiflottantes) sont à l'étude (Hakoun, 2013), et en voie de production.

L'instrumentation est également en plein essor : de plus en plus de grandeurs physico-chimiques et physiques peuvent être enregistrées de manière automatique, et ce de façon spatialisée, grâce à la baisse des coûts des capteurs. Des bases de données de mesures peuvent donc être réalisées sur plusieurs années à une fréquence d'échantillonnage suffisamment fine pour permettre la description des processus hydrodynamiques à différentes échelles de temps. Également la multiplication de capteurs sur l'étendue du bassin d'alimentation permet de capitaliser des données utiles pour la description spatiale des processus, que nous avons présentés comme anisotropes.

Dans le cas de l'hydrosystème du Lez, les observatoires MEDYCYSS et SO KARST ont pour objectif de fédérer l'instrumentation et l'étude des aquifères karstiques afin de pérenniser l'acquisition de longues chroniques susceptibles de pouvoir permettre de mieux appréhender les effets du changement climatique global et de l'exploitation de la ressource.

### 1.4.2. CARACTERISATION ET CONCEPTUALISATION

La compréhension et la caractérisation du fonctionnement hydrodynamique, à partir des observations, fait nécessairement appel à différentes conceptualisations et à différents modèles-hypothèse. Ces hypothèses vont par exemple motiver la réalisation d'expériences *in situ* (traçages, essais par pompage, etc.). Même si le modèle sous-jacent (souvent linéaire) n'est pas toujours en adéquation avec la morphologie complexe et la distribution des vides karstiques, ces investigations permettent néanmoins d'apporter un certain niveau d'information qui peut se révéler précieux. Par exemple, les traçages (Figure 8) permettent de prouver le lien entre deux compartiments ou de mieux appréhender l'extension du bassin d'alimentation d'une source. Les

expériences de pompage permettent d'estimer le volume d'un réservoir équivalent ou encore des propriétés hydrodynamiques estimées à partir d'hypothèses conceptuelles, comme la notion de double porosité.




Figure 8 : Injection de traceur à partir d'un réseau souterrain.

Le développement des méthodes de géochimie et de microbiologie, appliquées aux systèmes karstiques, permet de mieux appréhender le fonctionnement hydrodynamique des différents compartiments du karst et donc d'affiner les approches conceptuelles. Les analyses géochimiques et microbiologiques assurent une meilleure compréhension des temps de résidence de l'eau au sein du karst. Ces méthodes permettent aussi d'identifier des zones de contribution par la signature géochimique des eaux. Ce type de résultat peut permettre d'améliorer la représentation conceptuelle des transferts souterrains comme le montrent les résultats des travaux de thèse de Bicalho (2010) qui conduisent à prendre en compte une part d'apports profonds identifiés par leur signature géochimique.

L'étude hydrodynamique du karst s'effectue à l'échelle régionale, soit par regroupement d'observations locales à partir d'un schéma fonctionnel comme celui proposé par Mangin (1975), soit par une approche plus globale appliquée à l'ensemble du système (Mangin, 1975). Cette approche permet la caractérisation du fonctionnement hydrodynamique du karst à partir de la mesure des flux en entrée et en sortie du système (précipitations, débit, niveau piézométrique, etc.).

La caractérisation du fonctionnement de l'hydrosystème par une approche conceptuelle revient à considérer que celui-ci effectue différentes opérations, correspondant à autant de processus hydrologiques, auxquelles on cherche à associer des fonctions mathématiques. Ce type d'approche peut concerner l'ensemble du fonctionnement hydrodynamique ou seulement une partie comme le tarissement, la crue, la décrue, etc. C'est le cas par exemple de l'analyse des courbes de récession dont la loi proposée par Maillet (1905) a été reprise dans de nombreux travaux comme ceux de Padilla et al. (1994).

### 1.4.3. MODELISATION

Il est courant de considérer que la bonne adéquation de la sortie d'un modèle avec la mesure observée est gage de la validité physique de l'hypothèse sous-tendue par le modèle. Or en hydrologie, compte-tenu des incertitudes liées à la mesure sur le terrain, ce principe est généralement faux dès lors que le modèle a été soumis à un calage. On peut le vérifier facilement en déployant des modèles d'hypothèses physiques différentes et en constatant que leurs performances sont semblables en simulation. Ceci est particulièrement vrai pour les aquifères karstiques dont l'observation est encore plus incomplète que celle des systèmes de surface.

Ceci ne signifie pas que la modélisation est nécessairement vouée à l'échec ; G. E. Box disait « *Tous les modèles sont faux ; certains sont utiles* » (Box, 1979) ; ceci signifie que l'objet de la conception du modèle doit être bien défini et que la méthode de validation du modèle sur des données complètement indépendantes doit faire partie intégrante de sa conception. Par exemple on peut réaliser un modèle de prévision des crues en prévoyant qu'il sera validé sur différents types de crues, en particulier les plus intenses.

Compte tenu du manque de connaissances sur l'objet physique « karst », il y a peu de modèles opérant sur le karst réalisés à partir d'hypothèses physiques ; on pourrait cependant citer le travail de Mangin (1969) pour expliquer le fonctionnement intermittent de la source de Fontestorbes dans les Pyrénées ariégeoises. Le modèle peut ainsi contribuer à la compréhension du système, il est aussi susceptible d'en prévoir certains comportements.

De façon générale, les modèles utilisés pour représenter le fonctionnement hydrodynamique du karst ont pour objectif de représenter les évolutions d'une variable du système (débit, niveau piézométrique). Pour ce faire, l'approche conceptuelle est le plus souvent utilisée. Celle-ci consiste généralement à utiliser le concept du réservoir. Les principaux compartiments du karst sont alors représentés par des réservoirs ayant différentes propriétés. Les réservoirs vont se remplir et se vider en répondant à deux fonctions : i) production (entrée-réservoir), ii) transfert (réservoir-sortie). Ces fonctions font appel à des paramètres qu'il va falloir ajuster lors d'une phase de calage. Cette phase de calage est un domaine d'étude sensible puisqu'elle conditionne les résultats et l'interprétabilité éventuelle de la valeur des paramètres du modèle. Une partie des paramètres peut éventuellement être fixée à partir de données obtenues en étudiant l'hydrogramme unitaire comme l'on présenté Fleury et al. (2007).

Une autre alternative est possible qui propose une vision systémique de cet hydrosystème. Cette approche systémique, renforcée par l'auto-organisation globale mise en évidence en étudiant la perméabilité (section 1.1.2 de ce chapitre), est mise en œuvre par l'utilisation de modèles de type boîte noire. Dans cette vision on cherche à calculer des fonctions mathématiques liant au mieux les entrées et les sorties du système étudié, sans préjuger d'une fonction physique explicite. L'objectif de cette modélisation est alors de minimiser une erreur grâce à une fonction mathématique très souple qui permet de transcrire à la fois les non-linéarités mais aussi les dynamiques multi-échelles des écoulements. Les méthodes d'analyse et de modélisation systémiques, qui sont au cœur de ce travail de thèse, font respectivement l'objet des chapitres 2 et 3.

#### 1.4.4. EVALUATION ET VALIDATION

Les hypothèses autant que les modèles doivent être évalués afin d'assurer leur validité dans un domaine bien défini. Avant toute étape d'évaluation (hypothèse, modèle) il faut avoir conscience de la qualité de l'observation initiale (mesure, cartographie, etc.). Cette qualité permet de cibler pertinemment le niveau de précision recherché et le degré d'exactitude correspondant. L'étape suivante est le choix des critères d'évaluation. Là aussi, il y faut identifier les indicateurs pertinents, adaptés à l'objectif visé, ils peuvent être visuels, graphiques, numériques. Pushpalatha et al. (2012) proposent un examen des critères utilisables pour l'évaluation de la simulation des basses eaux qui peut être particulièrement utile pour représenter au mieux les étiages. De façon plus générale, Bennett et al. (2013) proposent un ensemble de méthodes et de critères pour évaluer les performances des modèles. Une démarche similaire est adoptée dans ce travail puisque les modèles seront évalués à partir du critère de Nash, mais aussi à partir d'analyses systémiques afin d'étudier en détail les performances et surtout les défauts des modèles utilisés.

L'évaluation et la validation des hypothèses et des modèles peuvent aussi passer par : i) l'expérimentation *in situ*, comme nous l'avons vu dans le cas des traçages, ii) la confrontation avec les observations ou encore la confrontation à d'autres modèles, d'autres approches.



## 1.5. CONCLUSION DU CHAPITRE 1

Ce chapitre s'est attaché à montrer que le karst n'est pas qu'un beau paysage calcaire atténuant aussi bien les crues que les étiages au travers d'une réponse hydrodynamique difficile à interpréter. Nous avons tout d'abord présenté la définition moderne du karst comme un ensemble d'entités géomorphologiques de surface et souterraines ainsi que de conditions hydrodynamiques. La Figure 9 illustre une cavité de taille considérable située actuellement dans la zone épinoyée (même si elle a dû être creusée en régime noyé) ; le remplissage de la cavité et l'amplitude des variations du niveau piézométrique témoignent d'une dynamique complexe, surtout dans la zone de battement de la nappe.

La formation des karsts est un processus hétérogène, anisotrope et polyphasé donnant lieu à un objet physique extrêmement complexe et difficile à analyser en l'absence de connaissance exhaustive sur les vides existants et les forçages multiples appliqués. Les représentations conceptuelles puis fonctionnelles du karst nous ont permis de mettre en évidence la pluralité des compartiments interagissant en s'échangeant des flux de matière ou d'énergie. Nous avons alors pu présenter le karst comme un hydrosystème recevant des entrées et délivrant des sorties.



Figure 9 : Galeries basses de la grotte de la Cocalière (Gard, France) : conduit appartenant à la zone épinoyée.

Ensuite, nous avons souligné la non-linéarité du fonctionnement de ce type d'hydrosystème ainsi que la variété des processus hydrodynamiques et la diversité des échelles temporelles qui y interviennent.

Enfin les approches et méthodes de caractérisation, de compréhension et de représentation du fonctionnement hydrodynamique du karst ont été évoquées afin de souligner d'une part leur complémentarité et leur indissociabilité, et d'autre part leurs limites et les limites des modélisations qui en découlent.

Les hydrosystèmes karstiques, en l'état actuel des connaissances et des moyens d'investigation géophysiques, sont encore mal connus et les méthodes physiques peu adaptées de ce fait à leur représentation, c'est pourquoi nous avons proposé dans ce travail d'adopter une approche d'analyse et de modélisation systémique, décrivant les échanges de flux au sein du système grâce à des fonctions mathématiques paramétrables. La présentation de cette approche systémique fait l'objet du chapitre suivant (chapitre 2), tandis que l'approche de modélisation systémique sera présentée au chapitre 3.

## 2. APPROCHE SYSTEMIQUE : METHODES D'ANALYSE ET DE PRETRAITEMENT

L'étude hydrodynamique des systèmes karstiques peut s'effectuer selon différentes approches, physiques ou conceptuelles, évoquées au chapitre précédent. Néanmoins, comme nous l'avons soulevé précédemment, ces méthodes sont limitées d'une part par le manque d'information sur l'objet physique « karst », en ce qui concerne les modèles à base physiques, et d'autre part, par le manque de connaissance sur les processus, en ce qui concerne les modèles conceptuels basés sur les processus. Des progrès ont toutefois été réalisés dans ces domaines au cours de dix dernières années et permettent d'approfondir les connaissances sur les karsts et leurs propriétés hydrodynamiques. En revanche, l'approche systémique, qui considère le système complexe dans son ensemble, comme un système composé de différentes « boîtes », qui sont autant de filtres représentant à différents degrés la connaissance que l'on a des processus physiques, est une approche qui va nous permettre de représenter le système dans sa globalité à partir de la seule connaissance de ses signaux d'entrée et de sortie, sans hypothèse physique ou conceptuelle.

L'approche systémique est le sujet de ce chapitre, elle sera présentée tout d'abord dans le cadre de la modélisation linéaire et invariante des systèmes, telle que proposée par Jenkins et Watts en 1968, puis nous nous attacherons à élargir le spectre des possibilités de cette analyse en présentant de nouveaux outils et concepts qui permettront d'une part de décomposer le signal temporellement et d'autre part de concevoir des fonctions non-linéaires et variantes dans le temps.

Ainsi la première partie de ce chapitre présente le schéma fonctionnel du karst tel que présenté par A. Mangin en 1975, puis la seconde partie s'intéresse aux méthodes d'analyses corrélatoires et spectrales simples et croisées et leur utilisation pour l'étude des composantes temporelles relatives au fonctionnement hydrodynamique du karst. La troisième partie présente des méthodes de prétraitement visant à filtrer ou décomposer les signaux selon différentes échelles temporelles.

### 2.1. SCHEMA FONCTIONNEL ET APPROCHE SYSTEMIQUE DU KARST

Notre travail est fondé sur l'approche globale du schéma fonctionnel du karst (Mangin, 1975) comme l'illustre la Figure 10. Ce schéma fonctionnel correspond à une mise en cascade de « boîtes » en interaction qui représentent les processus hydrodynamiques majeurs du karst. Chacune de ces boîtes correspond à un ou plusieurs réservoirs qui vont assurer les fonctions de production (recharge) et de transfert (vidange). Le remplissage de ces boîtes se fait en fonction des propriétés de l'hydrosystème étudié et des objectifs à atteindre. Les systèmes annexes (Figure 10) pourront ainsi représenter : une ou plusieurs parties du réseau, la matrice, des « compartiments » de l'hydrosystème, etc ... L'ensemble des fonctions associées aux différentes boîtes ont pour objectif de représenter le fonctionnement de l'hydrosystème. Or, nous avons vu dans le chapitre 1 que l'identification des propriétés physiques et des processus relatifs au fonctionnement de l'hydrosystème ne peut être réalisée de façon exhaustive. En revanche, lorsque l'instrumentation le permet, il est possible de disposer des données relatives aux entrées et aux sorties de l'hydrosystème.

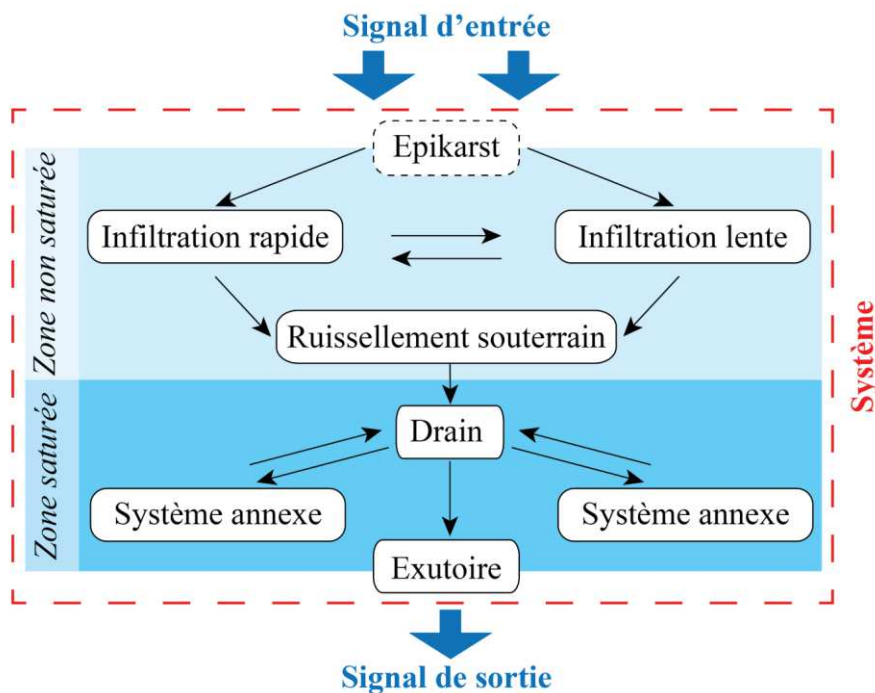


Figure 10 : Schéma fonctionnel selon l'approche établie par Mangin (1975).

Ces informations (ces signaux) d'entrée et de sortie contiennent *a priori* toute l'information nécessaire pour appréhender la transformation globale effectuée par le système. Ainsi, dans le cas des hydrosystèmes karstiques, la relation entrée-sortie permet d'étudier la réponse du système à une sollicitation extérieure comme la pluie. Cette réponse, comme on peut le voir sur la Figure 10, correspond à la combinaison de différentes fonctions, de différents processus hydrodynamiques. L'avantage de l'approche systémique est de limiter les hypothèses et la conceptualisation relatives au fonctionnement de l'hydrosystème karstique.

La démarche proposée dans ce travail est de partir de l'analyse systémique pour appréhender des informations qui seront utilisées pour : i) améliorer la connaissance du fonctionnement hydrodynamique du karst et des processus associés, ii) contraindre les modèles qui seront présentés au chapitre suivant.

Nous avons donc vu que l'ensemble des processus hydrodynamiques, conceptualisés et illustrés dans la Figure 10, pouvait être considérés comme un système réalisant différentes fonctions qui aboutissent à la transformation d'un signal d'entrée en un signal de sortie. La section suivante vise, dans un premier temps, à formaliser cette relation entrée-sortie du système naturel qu'est le karst. La suite sera consacrée aux méthodes d'analyse des signaux, d'abord de façon individuelle, pour mieux appréhender leur relation qui sera étudiée en croisant les informations d'entrée et de sortie. Dans le cas d'une entrée unique de pluie transformée en débit, les analyses simples et croisées permettent d'obtenir des informations sur la structure temporelle et les périodicités de la réponse du système.

## 2.2. ANALYSE SYSTEMIQUE DU KARST ET DE SES ECHELLES TEMPORELLES

### 2.2.1. PRESENTATION DES METHODES

#### 2.2.1.1. INTRODUCTION

L'analyse des systèmes a été développée par Jenkins et Watts (1968) et Box et Jenkins (1976) pour l'étude des systèmes artificiels. Elle a été reprise par Mangin (1981 ; 1984) pour être appliquée aux hydrosystèmes karstiques. L'analyse des systèmes repose sur l'étude de la relation liant les entrées et les sorties d'un système (Figure 10). Le système est considéré comme un opérateur mathématique ( $h(t)$ ) qui transforme un signal

d'entrée ( $x(t)$ ) en signal de sortie ( $y(t)$ ). Il peut donc être vu comme une « boîte noire » constituée d'un ensemble de fonctions qui filtrent le signal d'entrée pour produire un signal de sortie généralement atténué et déphasé par rapport à l'entrée (Figure 11).




Figure 11 : Représentation schématique de l'approche systémique.

Cette relation peut être étudiée dans les domaines temporel, fréquentiel, ou temps-fréquence, ce qui permet de visualiser l'information sur le système et ses entrées-sorties de façons complémentaires.

Dans le cadre de l'analyse systémique des hydrosystèmes, les signaux d'entrée sont généralement les variables de forçage climatique (précipitations, température de l'air, évapotranspiration, etc.). Les signaux de sortie sont des variables d'intérêt du système (niveau piézométrique, débit, conductivité, turbidité) qui renseignent sur son état ou sa dynamique. Dans notre étude, focalisée sur la modélisation hydrodynamique, les signaux d'entrée sont la pluie et éventuellement l'évapotranspiration, le signal de sortie est le débit à l'exutoire (Figure 11). Le signal de débit étudié peut être soit un débit mesuré, soit un débit estimé par modélisation. La comparaison des débits mesurés et simulés par les méthodes d'analyses systémiques permettent une investigation approfondie des performances du modèle.

Pour simplifier les raisonnements et le discours, le signal de débit (sortie) sera souvent considéré, dans le reste du manuscrit, comme une information d'état du système. Nous savons que ceci n'est pas rigoureusement exact puisque l'état est défini, en analyse des systèmes, comme le vecteur de dimension minimale permettant de décrire pleinement le système et de calculer toutes ses évolutions futures à partir d'un état initial et des évolutions des variables exogènes (variables d'entrée extérieures). Néanmoins, compte-tenu des informations généralement disponibles sur les hydrosystèmes que nous étudions, le débit qui correspond au transfert de pression au sein de l'aquifère et qui dépend de l'état hydrique du bassin hydrogéologique et des forçages appliqués en entrée, nous semble une variable intégratrice représentant assez bien la notion d'état.

Afin de mieux appréhender les transformations qu'opère le système sur ses variables d'entrée, il est utile d'analyser ces signaux d'entrée et de sortie ainsi que leurs éventuelles structures. Ces dernières analyses, lorsqu'elles s'appliquent à un signal seul, qu'il soit de pluie ou de débit, sont dites *simples*. Elles seront décrites dans un premier temps (section 2.1.1.1), par opposition aux analyses *croisées*, qui visent à décrire les relations entre deux signaux et qui seront présentées dans un second temps (section 2.1.1.2).

Certaines méthodes d'analyses simples appliquées au débit sont susceptibles de fournir des informations sur « l'opération » effectuée par le système, c'est-à-dire la transformation d'un signal de pluie que nous considérons comme aléatoire. Il faut pour cela que l'entrée respecte certaines conditions comme l'indépendance temporelle. Les résultats ainsi obtenus par l'analyse simple seront utilisés pour répondre à la démarche de classification des karsts proposée par Mangin (1984). On privilégiera toutefois les analyses croisées pour étudier plus spécifiquement le fonctionnement hydrodynamique du système.

## 2.1.1.1. ANALYSES SIMPLES

### 2.1.1.1.1. CORRELOGRAMME SIMPLE

L'analyse corrélatrice simple consiste à calculer la corrélation linéaire entre une série et elle-même décalée dans le temps. L'intérêt de ce type d'analyse est d'obtenir des informations sur la dépendance statistique du signal envers lui-même. On peut en déduire principalement plusieurs informations : i) la durée à partir de laquelle le signal devient indépendant de ses valeurs précédentes ; appelée « inertie » du signal par analogie avec la mécanique, ou « effet mémoire », ii) la présence d'éventuelles cyclicités.

Le calcul de la corrélation linéaire simple, ou autocorrélation, notée  $r_k$  est effectué de la manière suivante :

$$r_k = \frac{C_k}{\sigma_x \sigma_x}$$

Avec :

$$C_k = \frac{1}{n} \sum_{i=1}^{n-k} (x_i - \bar{x}) \cdot (x_{i+k} - \bar{x})$$

Avec  $k$  le décalage temporel ;  $x$  la série chronologique étudiée,  $\bar{x}$  sa moyenne,  $\sigma_x$  son écart-type et  $n$  son effectif. La représentation graphique du vecteur  $\mathbf{r}$  des corrélations en fonction du décalage temporel  $k$  est appelée *corrélogramme simple*, ou *autocorrélogramme*. L'autocorrélation étant calculée entre un signal et lui-même décalé dans le temps, les résultats obtenus sont les mêmes pour les décalages temporels positifs et négatifs. Le corrélogramme simple est donc symétrique par rapport à l'axe des abscisses c'est pourquoi seules les valeurs positives de  $k$  seront représentées graphiquement.

L'effet mémoire du système est défini (Mangin, 1984) comme la valeur de l'intervalle temps pour lequel la valeur de la corrélation passe en dessous du seuil de 0,2. Cette limite représente le seuil à partir duquel on considère que les deux signaux ne sont plus linéairement corrélés. Ce seuil peut être utilisé sous réserve de la validité de l'hypothèse de dépendance linéaire, ou pour effectuer une première analyse donnant des informations sur les structures temporelles sous-jacentes aux signaux. Ce seuil sera discuté par la suite (chap. 5) lorsque l'on s'intéressera plus spécifiquement à la non-linéarité du processus étudié.

Si le signal est aléatoire sa fonction d'autocorrélation est une impulsion de Dirac : ceci indique que chaque valeur à l'instant  $t$  est indépendante des autres valeurs. Sur la Figure 12 qui illustre l'autocorrélation du signal de pluie, on voit que pour  $k > 0$  toutes les valeurs du corrélogramme sont inférieures à 0,1 ce qui traduit l'indépendance des valeurs et permet de considérer la pluie comme une variable constituée d'impulsions de grandeurs aléatoires.

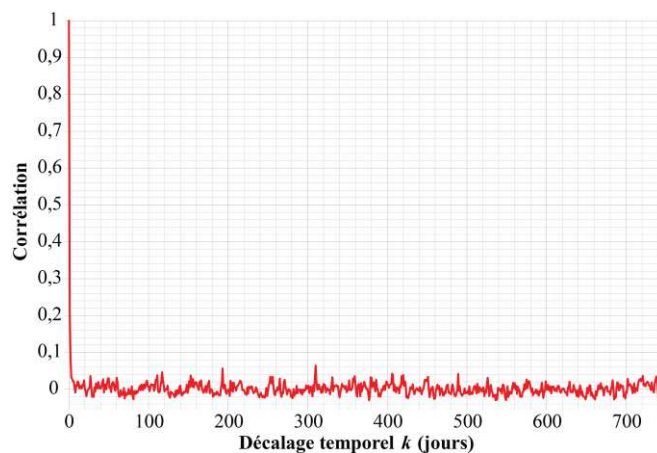


Figure 12 : Autocorrélation du signal de pluie enregistré à Valflaunès sur la période 1950-1967.

### 2.1.1.1.2. SPECTRE SIMPLE

L'analyse spectrale correspond à l'étude du signal dans le domaine fréquentiel. Les fréquences observées peuvent être reliées au temps par la relation :  $f = \frac{1}{T}$

La fréquence  $f$  correspond à l'occurrence de phénomènes, de processus, à différentes échelles de temps de période  $T$ . Plus un phénomène est présent dans le signal, avec une puissance forte, plus la valeur du spectre sera élevée pour la fréquence correspondante. A l'inverse une faible valeur du spectre traduit donc un phénomène très peu intense, même s'il est permanent ou très intense mais très peu fréquent (phénomène rare).

D'après le théorème de Wiener-Kinchine, le module du spectre (densité spectrale de puissance) d'un signal stationnaire peut être obtenu par la transformée de Fourier de la fonction d'autocorrélation de ce signal. Or, pour cette méthode, il faut limiter la profondeur du corrélogramme, c'est-à-dire le décalage temporel maximum, par l'utilisation d'une troncature  $m$ . Cette troncature a une incidence sur le spectre obtenu, puisqu'elle limite les périodes prises en compte, c'est-à-dire l'intervalle de fréquences étudiées. Le spectre  $S(f)$  est obtenu par le calcul suivant :

$$S(f) = 2 \left[ 1 + 2 \sum_{k=1}^m D_k r_k \cos(2\pi f k) \right]$$

Avec  $k$  le décalage en jours,  $m$  la troncature,  $f$  est la fréquence considérée,  $r_k$  le coefficient d'autocorrélation et  $D_k$  une fonction de pondération pour limiter les erreurs introduites par le fait que le calcul de  $S(f)$  est effectué sur une durée finie ; ce qui revient à multiplier le signal par une fenêtre de troncature.

La fonction de pondération de Turkey utilisée ici a été décrite par Mangin (1984). Elle est utilisée comme fonction de troncature car bien adaptée aux signaux hydrologiques pour la faible perte d'information associée à son utilisation. Son expression mathématique est la suivante :

$$D_k = \left( 1 + \cos \frac{\pi k}{m} \right) / 2$$

Le spectre est utilisé dans un premier temps pour étudier les périodicités comme nous l'avons expliqué précédemment. Sa représentation graphique s'effectue en échelles linéaires. A. Mangin (1984) a défini la fréquence de coupure comme étant la fréquence à partir de laquelle on considère le spectre comme négligeable. Cette fréquence sera notée  $F_{cM}$  car elle ne correspond pas à la fréquence de coupure telle que définie en analyse du signal. En effet, dans l'étude des filtres (analyses croisées), la fréquence de coupure, qui sera notée  $F_c$  correspond à la limite de la bande passante, c'est-à-dire la fréquence à partir de laquelle le signal va être atténué en amplitude de plus de 3 décibels (atténuation de  $\sqrt{2}$ ). La fréquence de coupure  $F_c$  correspond en fait à la fréquence utilisée dans Mangin (1984) pour calculer le temps de régulation, c'est-à-dire l'inverse de la fréquence pour laquelle le spectre de puissance est égal à la moitié de sa valeur maximale.

Le spectre est utilisé dans un second temps pour étudier le type de bruit correspondant à un signal donné. L'étude du bruit a pour but d'appréhender l'éventuelle structuration du signal. Sa représentation graphique se fait en échelles logarithmiques (Log-Log) pour permettre la lecture directe de toutes les valeurs en dépit de l'étendue de leur plage de variation. La pente observée permet de caractériser le type de bruit (Hausdorff et al., 1996), qui traduit un caractère aléatoire pour une pente nulle : c'est le bruit blanc qui caractérise le signal de pluie.

### 2.1.1.2. ANALYSES CROISEES

Les analyses croisées des signaux entrée-sortie ont pour objectif d'obtenir des informations sur la transformation opérée par le système étudié. On peut dégager deux représentations de cette transformation : l'une dans le domaine temporel, l'autre dans le domaine fréquentiel.

### 2.1.1.2.1. CORRELOGRAMME CROISE

Si le système étudié est linéaire, rappelons que sa réponse impulsionnelle correspond à la fonction  $h(t)$  définie par ses signaux d'entrée  $x(t)$  et de sortie  $y(t)$ . Cette relation peut être exprimée par le produit de convolution suivant :

$$x(t)*h(t)=y(t)$$

Il existe plusieurs possibilités pour déterminer la réponse impulsionnelle : i) le calcul de l'intégrale de convolution, ii) l'utilisation du corrélogramme croisé. C'est cette seconde option qui est utilisée dans ce travail.

Dans cette démarche la corrélation linéaire est calculée entre une série d'entrée échantillonnée  $x$  et une série de sortie  $y$ , également échantillonnée et progressivement décalée dans le temps. La corrélation croisée  $r_{xy}$  s'exprime mathématiquement de la façon suivante :

$$r_{xy}(k) = \frac{C_{xy}(k)}{\sigma_x \sigma_y}$$

Avec :

$$C_{xy}(k) = \frac{1}{n} \sum_{i=1}^{n-k} (x_i - \bar{x})(y_{i+k} - \bar{y})$$

Avec  $k$  le décalage temporel,  $x$  la série chronologique d'entrée,  $\bar{x}$  sa moyenne,  $\sigma_x$  son écart type,  $y$  la série chronologique de sortie,  $\bar{y}$  sa moyenne,  $\sigma_y$  son écart type et  $n$  l'effectif des séries. La représentation graphique du vecteur  $r$  est appelée corrélogramme croisé, elle peut se faire pour les décalages temporels  $k$  positifs et négatifs. Pour les  $k$  négatifs, la corrélation doit, *a priori*, être quasi nulle puisque la sortie n'est pas censée avoir d'influence sur l'entrée. La validation de cette hypothèse permet de vérifier la causalité de la relation entrée sortie, c'est-à-dire que la pluie détermine le débit, et non l'inverse.

Dans le cas d'un système linéaire et invariant, le corrélogramme croisé (Figure 13) correspond à la réponse impulsionnelle du système à un signal d'entrée aléatoire. Celle-ci permet d'identifier le temps de réponse comme étant la durée nécessaire pour observer la réponse maximale du système à une impulsion de pluie en entrée, c'est-à-dire le transfert de pression associé à une sollicitation extérieure. Le seuil 0,2 permet de déterminer le décalage temporel  $k$  à partir duquel les séries d'entrée et de sortie ne sont plus linéairement corrélées, et deviennent donc indépendantes.

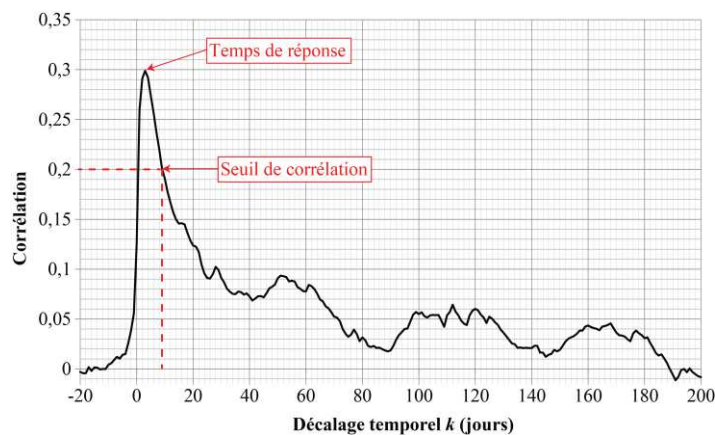


Figure 13 : Corrélogramme croisé pluie-débit de l'hydrosystème karstique du Lez sur la période 1950-1967.

Si l'on considère que l'hydrosystème karstique répond aux conditions de linéarité et d'invariance, il est possible d'utiliser les informations obtenues par les analyses corrélatoires et spectrales simples et croisées pour situer le karst étudié dans la classification relative des karsts proposée par Mangin (1984). Cette classification sera présentée au chapitre 5 lors de l'application des méthodes d'analyses simples et croisées à l'hydrosystème du

Lez. Cette classification relative des karsts permet d'appréhender le fonctionnement hydrodynamique (type de drainage, capacités de stockage) de l'hydrosystème étudié par rapport à des hydrosystèmes de référence.

#### 2.1.1.2.2. FONCTION DE TRANSFERT

La fonction de transfert correspond à la transformation opérée par le système dans le domaine fréquentiel. Comme pour l'analyse simple, la relation de Wiener-Kinchine permet de passer du domaine temporel au domaine fréquentiel (spectral). Dans le domaine de Fourier, le produit de convolution  $x(t)*h(t)=y(t)$  s'exprime comme un produit simple :

$$X(f)H(f)=Y(f)$$

Avec  $X(f)$  la transformée de Fourier de l'autocorrélation du signal d'entrée,  $Y(f)$  la transformée de Fourier du signal de sortie et  $H(f)$  la fonction de transfert.

La fonction de transfert est la transformée de Fourier de la réponse impulsionnelle. Comme cette dernière, elle n'est définie que pour un système linéaire et est unique pour ce système. De même que pour le spectre simple, la fonction de transfert peut être représentée en échelles logarithmiques pour faciliter l'étude du système. Elle décrit donc les opérations de filtrage effectuées par le système. À chaque abscisse  $f$ , l'ordonnée indique la puissance de l'onde sinusoïdale de fréquence  $f$ . Cela permet donc de distinguer les fréquences que le filtre amplifie et celles qu'il atténue. La limite entre les fréquences amplifiées et atténuées correspond à la fréquence de coupure  $F_c$  qui se traduit par l'apparition d'une ou plusieurs pentes. Il est aussi possible de déterminer l'ordre du filtre (lié à l'intensité de la décroissance des hautes fréquences), et d'autres fréquences de coupure par d'éventuelles ruptures de pentes.

### 2.2.2. CAS DES SYSTEMES NON-LINEAIRES ET NON-STATIONNAIRES

La présentation des hydrosystèmes karstiques (Chapitre 1) a montré le caractère non-linéaire de ces systèmes. La pluie, qui constitue l'entrée du système, n'est ni invariante (stationnaire), ni complètement aléatoire. De plus, le système lui-même n'est pas invariant, c'est-à-dire que son fonctionnement est susceptible d'évoluer dans le temps en fonction de son état hydrique ou encore de modifications comme le remplissage ou le décolmatage d'une partie du réseau. Pour ces raisons, le système étudié ne possède pas une unique *réponse impulsionnelle*, ni une unique fonction de transfert. Ces observations conduisent donc à proposer des solutions permettant l'utilisation des méthodes proposées précédemment.

#### 2.2.2.1. DOMAINE TEMPOREL

L'analyse du système dans le domaine temporel correspond ici à l'étude de la *réponse impulsionnelle* par la corrélation croisée. Or, nous avons vu que celle-ci n'existe pas pour un système non-linéaire ou non-stationnaire en ce sens que cette *réponse impulsionnelle* n'est plus unique pour aucune des deux configurations.

Pour étudier l'effet de la non stationnarité certains auteurs (Bailly-Comte et al., 2011 ; Delbart et al., 2014) calculent la corrélation croisée sur une fenêtre temporelle glissante. Dans ce cas, les auteurs limitent le décalage temporel par l'utilisation d'une troncature  $m$  déjà définie dans la présentation du spectre simple. L'utilisation de cette méthode permet d'étudier la variabilité de la *réponse impulsionnelle* en fonction des saisons et de la variabilité interannuelle.

La non-linéarité de la relation pluie-débit peut aussi être associée à l'intervention d'une autre variable comme l'évapotranspiration. L'utilisation de la pluie efficace comme signal d'entrée est susceptible de fournir une information suffisante pour « linéariser » la relation entrée sortie, pourvu que la non-linéarité soit associée au fait que toutes les variables d'entrées ne sont pas prises en compte. Une estimation de la pluie efficace par une méthode de modélisation inverse à partir d'un modèle non-linéaire sera d'ailleurs proposée dans la dernière



section des résultats de ce travail de thèse. Néanmoins, l'étude d'une éventuelle linéarisation de la relation pluie-débit par l'utilisation de la pluie efficace est une piste que nous n'avons, à l'heure actuelle, pas explorée.

Dans la suite du travail, par facilité, nous continuerons à utiliser le terme de « réponse impulsionnelle » concernant la fonction obtenue par analyse croisée d'un système non linéaire, même si nous savons que celle-ci n'est pas définie ; pour cette raison nous la noterons en italiques.

Cette dernière constatation nous amène à émettre l'hypothèse que l'information contenue dans les valeurs de la *réponse impulsionnelle* en dessous du seuil 0,2, pourrait transcrire un fonctionnement du système. Cette hypothèse conduit à approfondir la caractérisation de la *réponse impulsionnelle* au travers de : i) l'étude de la contribution des pluies à long terme pouvant expliquer le débit de base observé en saison sèche ; ii) l'analyse des ruptures de pente qui semblent correspondre à l'intervention de processus hydrodynamiques à différentes échelles de temps. L'étude de la *réponse impulsionnelle* (Chapitre 5) conduira à l'identification de processus empiriques correspondant au fonctionnement du système, ces derniers seront utilisés pour contraindre les modèles par réseaux de neurones qui seront présentés au chapitre suivant. L'un des objectifs de l'utilisation de ces modèles non-linéaires sera d'évaluer la pertinence des informations extraites des valeurs du corrélogramme en dessous du seuil de corrélation linéaire de 0,2.

#### 2.2.2.2. DOMAINE FREQUENTIEL

Le passage du domaine temporel au domaine fréquentiel, c'est-à-dire de la réponse impulsionnelle à la fonction de transfert, offre une vision complémentaire de la relation pluie-débit. Comme nous l'avons vu précédemment, la fonction de transfert permet d'appréhender le type de filtrage opéré par le système. Au-delà du type de filtrage, nous avons vu qu'il est possible d'établir l'ordre du filtrage effectué par le système. Or, si l'on s'intéresse aux fréquences filtrées, il est possible d'identifier des ruptures de pentes, plus ou moins prononcées, qui correspondent à une modification de la transformation opérée selon les bandes de fréquences correspondantes. L'étude de la fonction de transfert permet aussi l'identification de phénomènes périodiques induits par le système si ce dernier est soumis à une entrée de type bruit blanc (ce qui est généralement le cas pour la pluie comme nous l'avons déjà discuté).

Les solutions proposées pour pallier à la non-linéarité et à la non-stationnarité dans le domaine temporel sont aussi applicables dans le domaine fréquentiel puisqu'il qu'il s'agit simplement d'un changement de domaine.

### 2.3. METHODES DE PRETRAITEMENT TEMPOREL DES SIGNAUX

#### 2.3.1. INTRODUCTION

Les signaux d'entrée et de sortie sont composés de hautes, moyennes et basses fréquences auxquelles sont associés différents types de processus, de phénomènes périodiques. C'est-à-dire que selon la fréquence considérée, l'opération effectuée par le système est spécifique. Dans le cas des signaux hydrologiques, les fréquences les plus hautes peuvent être considérées comme un bruit de mesure. Afin d'étudier les différents phénomènes périodiques, il est possible d'utiliser des filtres pour supprimer ou isoler certaines fréquences du signal. C'est le cas de l'étude des tendances qui concerne les basses fréquences et pour laquelle on peut utiliser une moyenne mobile pour filtrer les moyennes et hautes fréquences (Fatmi, 2009).

Étant donné que la réponse de l'hydrosystème karstique se compose de processus qui interviennent à différentes fréquences, il peut être utile pour l'étude comme pour la modélisation d'isoler certaines parties de la réponse en essayant de cibler des processus supposés. En effet, suite à un épisode pluvieux, le karst est susceptible de réagir rapidement avec un pic de crue. Selon sa structure, son développement et son état, l'hydrosystème va aussi remplir différentes fonctions de transfert et de stockage qui vont engendrer des contributions retardées et étalées de la pluie.

Il existe différentes méthodes de prétraitement qui permettent d'effectuer le filtrage de certaines fréquences du signal, elles seront sélectionnées en fonction de leur sélectivité et du déphasage qu'elles entraînent. Ces méthodes peuvent être utilisées pour décomposer le signal en un nombre donné de composantes contenant essentiellement les informations relatives aux bandes de fréquences désirées.

Cette section aborde donc, dans un premier temps, le type de filtre utilisé en fonction des contraintes relatives aux signaux et aux systèmes étudiés. La décomposition du signal en composantes fréquentielles est abordée pour illustrer l'approche de décomposition multirésolution d'un signal.

## 2.3.2. METHODES DE FILTRAGE

### 2.3.2.1. CHOIX DU TYPE DE FILTRE UTILISE

Les modèles statistiques utilisés dans cette thèse (présentés dans le chapitre suivant) sont, *a priori*, plus à même de représenter des signaux dont la distribution est gaussienne (maximum de vraisemblance). Or, comme il sera montré dans le chapitre 5, la distribution des séries chronologiques d'entrée et de sortie du système étudié est fortement influencée par quelques valeurs extrêmes. Il est donc apparu pertinent d'appliquer des filtres passe-bas coupant de plus en plus de hautes fréquences. Pour ce faire notre choix s'est porté sur l'utilisation de la moyenne mobile unilatérale qui n'utilise que des valeurs brutes précédentes afin de ne pas prendre en compte d'informations futures à l'instant  $t$  considéré qui viendraient perturber les performances du modèle, surtout en cas d'utilisation en prévision. La moyenne mobile unilatérale est donc un filtre passe-bas causal. L'application de ces filtres aux chroniques de débit a fait l'objet d'une communication orale lors de la 8<sup>ème</sup> conférence internationale de l'International Association of Geomorphologists qui s'est tenue à Paris en Août 2013 (résumé en Annexe C). Un retour sur ces résultats est effectué dans le chapitre 5.

L'expression mathématique d'une série filtrée  $x_{MMU}$  par la moyenne mobile unilatérale (MMU) d'ordre  $n$  à l'instant  $t$  est la suivante :

$$x_{MMU(t)} = \frac{x_{(t)} + x_{(t-1)} + \dots + x_{(t-(n-1))}}{n}$$

Avec  $x$  la série brute,  $n$  l'ordre du filtre, c'est-à-dire le nombre de jours précédents utilisés pour le calcul.

Or, sur la Figure 14a on observe que l'utilisation de ce filtre entraîne une perte importante de la structure de la série filtrée par rapport à l'observée, c'est-à-dire qu'on ne conserve que la tendance. Pour limiter ces pertes, il est possible de proposer un filtre, inspiré de la moyenne mobile unilatérale, mais ne présentant pas une sélectivité aussi importante (Figure 14b). Celui-ci consiste à affecter plus de poids aux données récentes (Figure 14c) tout en atténuant la variance instantanée. On va donc pondérer différemment chaque date utilisée comme suit :

Pour un filtre d'ordre  $n$  chaque valeur se voit affecter un poids qui décroît au fur et à mesure de son éloignement de l'instant  $t$ . Le poids  $P$  de la première valeur, à l'instant  $t$ , vaut :  $P(t) = \left(\frac{1}{1}\right)^2$  ; le poids de la seconde valeur vaut :  $P(t-1) = \left(\frac{1}{2}\right)^2$  ; et ainsi de suite jusqu'à la dernière valeur prise en compte dont le poids vaut  $P(t-(n-1)) = \left(\frac{1}{n}\right)^2$ .

L'expression mathématique du calcul de la valeur filtrée  $x_{MMUP(t)}$  devient donc :

$$x_{MMUP(t)} = \frac{\sum_t^{t-(n-1)} x_t P(t)}{\sum_t^{t-(n-1)} P(t)}$$

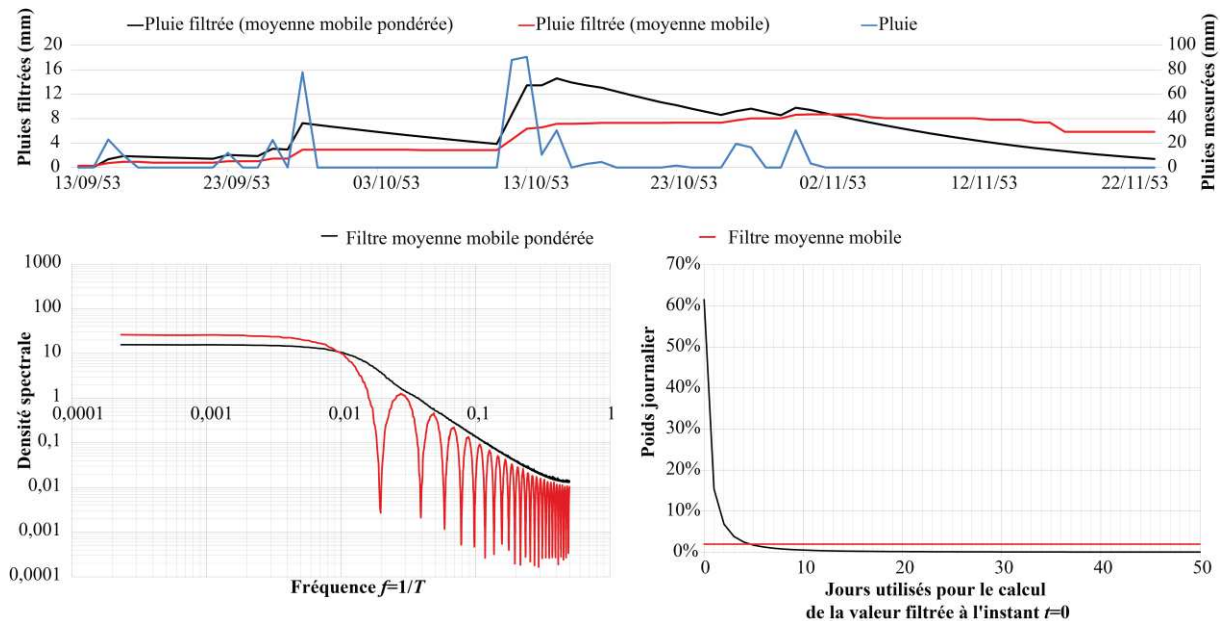


Figure 14 : Description des filtres moyenne mobile unilatérale (MMU) et moyenne mobile unilatérale pondéré (MMUP) d'ordre  $n=51$  jours. a) Séries de pluies brutes et filtrées ; b) Fonctions de transfert des filtres ; c) Poids relatifs affectés aux valeurs lors du calcul des séries filtrées.

Sur la Figure 14b on constate que le filtre MMU est plus sélectif et qu'il amplifie à peine plus la bande passante que le filtre MMUP. En revanche, le filtre MMUP permet de supprimer les ondulations de la bande atténuée du spectre associé au filtre passe-bas MMU. La sélectivité du filtre MMU peut être utile pour l'étude des tendances, mais pour la décomposition proposée par la suite, il est important de conserver l'information relative à la présence de pics (phases de croissance/décroissance).

### 2.3.2.2. DECOMPOSITION MULTIRÉSOLUTION PAR FILTRAGE PASSE-BANDE

La décomposition des signaux présentée ci-après est proposée comme alternative à la décomposition multirésolution en ondelettes orthogonales introduite dans l'étude des karsts par Labat et al. (2000) et utilisée en entrée d'un modèle de réseau de neurones par Johannet et al. (2012a). Le choix d'une décomposition alternative à la décomposition multirésolution en ondelette a été motivé par un souci de flexibilité des échelles temporelles, mais aussi pour des propriétés de causalité et d'invariance par translation qui ne sont pas toujours respectées en fonction de l'ondelette utilisée.

La méthode proposée consiste donc à effectuer une décomposition du signal par filtrage passe-bande pour isoler des bandes de fréquences choisies (Figure 15). L'objectif est d'isoler les informations relatives à certains processus empiriques, à certaines propriétés du filtrage effectué par l'hydrosystème.

La décomposition appelée dans le reste de ce travail « *Taverlette* » correspond à une succession de filtres passe-bas appliqués au signal brut, puis aux résidus du filtrage précédent. Le filtre utilisé est la MMUP car elle permet de conserver une partie de la structure du signal brut.

L'ordre des filtres est sélectionné à partir des composantes temporelles et fréquentielles identifiées à partir de l'analyse de la fonction de transfert, de la réponse impulsionnelle et des supposés processus sous-jacents. Or, l'échelle la plus fréquemment utilisée en décomposition multirésolution par ondelettes est l'échelle dyadique ( $2^\alpha$ ) (Labat et al., 2000), où  $\alpha$  est le nombre de composantes générées, qui n'est pas spécifiquement adaptée aux composantes temporelles des variables hydrologiques et climatiques.

La Figure 15 illustre schématiquement le procédé de décomposition multirésolution, on y voit que chaque valeur de la série brute contient différentes fréquences représentées par les cercles colorés (pleins ou en contour). Le cercle rouge (le plus grand) correspond aux basses fréquences et le cercle rempli de vert

correspond aux fréquences les plus hautes. On va ainsi séparer progressivement toutes les informations par bandes de fréquences. Ce schéma permet aussi de voir que la série brute peut être reconstituée en additionnant toutes les composantes.

Les étapes de décomposition (Figure 15) sont :

- 1) Calcul de la composante n°1 par filtrage de la série brute par la MMUP d'ordre  $n_1$  (le plus grand).
- 2) Calcul du résidu  $r_{n1}$  associé à l'étape 1 pour chaque instant  $t$  :  $r_{n1}(t) = x(t) - x_{MMUP_{n1}}(t)$
- 3) Calcul de la composante n°2 par filtrage du résidu  $r_{n1}$  par la MMUP d'ordre  $n_2$ .
- 4) Idem que l'étape 2 mais pour le résidu  $r_{n2}$  associé à l'étape 3.
- 5) Idem que l'étape 3 pour la composante n°3 avec la MMUP d'ordre  $n_3$  appliquée à  $r_{n2}$ .
- 6) Calcul du résidu final qui correspond à la « *composante résiduelle* » qui contient le reste de l'information.

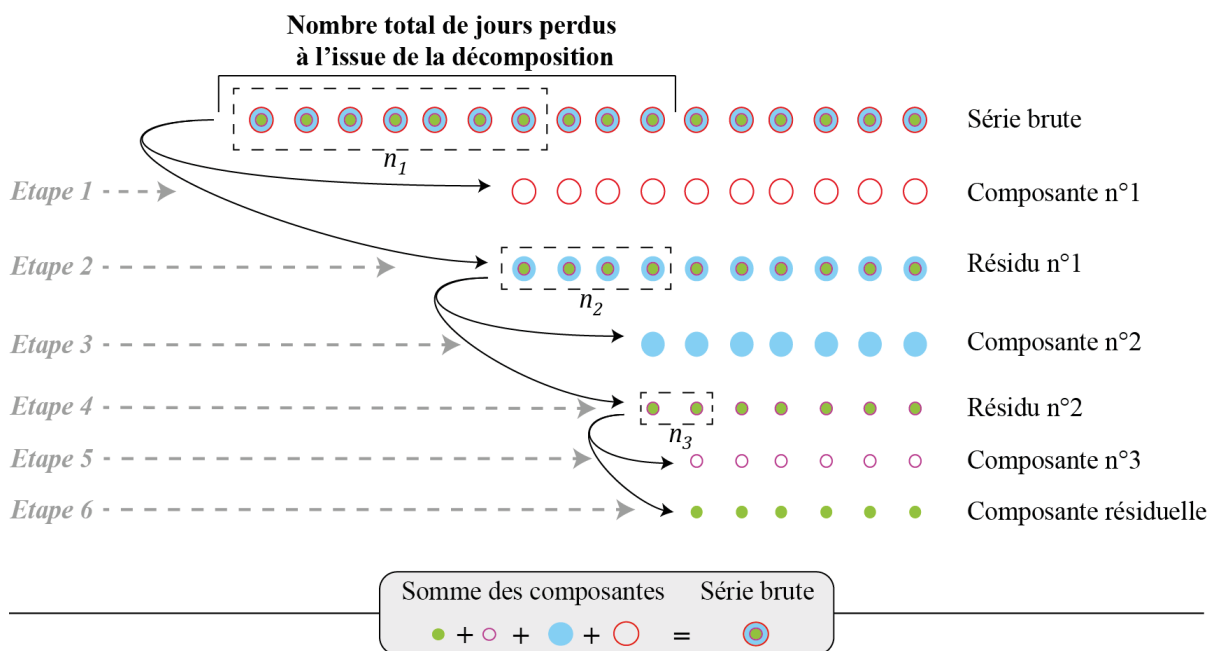


Figure 15 : Représentation schématique de la décomposition multirésolution "Taverlette". Les différents cercles correspondent aux informations relatives à des bandes de fréquences données séparées au cours de la décomposition. Les rectangles en tirets correspondent aux ordres  $n_\alpha$  des filtres utilisés.

On constate ainsi que l'application de cette décomposition engendre la perte d'un certain nombre de valeurs qui dépend de l'ordre des filtres utilisés et de leur nombre. On voit en effet que chaque étape de filtrage génère une diminution de l'effectif total égale à  $n_\alpha - 1$  ( $n_\alpha$  est l'ordre du filtrage à l'étape  $\alpha$ ).

Finalement, la décomposition proposée répond bien aux exigences en termes : i) de causalité, c'est-à-dire que les MMUP n'utilisent que des informations à l'instant  $t$  et aux instants précédents ; ii) d'invariance par translation, ce qui signifie que peu importe où débute la décomposition, un instant  $t$  donné aura toujours la même valeur ; iii) de flexibilité des échelles temporelles. Il est aussi possible de changer le filtre en utilisant la moyenne mobile unilatérale de façon « classique » ou avec une pondération différente de celle proposée pour la MMUP présentée dans ce chapitre.

### 2.3.3. CONCLUSION SUR LE PRETRAITEMENT DES SIGNAUX

L'approche systémique peut conduire à s'intéresser à des phénomènes périodiques correspondant à des échelles de temps différentes. Dans ce cas, il peut être utile de ne s'intéresser qu'à certaines fréquences du

signal. Le filtre MMUP proposé vise à supprimer les hautes fréquences tout en conservant une partie de la structure du signal. L'utilisation de la *Taverlette* pour la décomposition permet d'isoler des bandes de fréquences choisies correspondant à des composantes temporelles. Celles-ci seront utilisées par la suite comme variables d'entrée des modèles de réseaux de neurones afin d'étudier, par le modèle, la contribution de chaque composante au débit en sortie.

## 2.2. CONCLUSIONS SUR L'UTILISATION DE L'APPROCHE SYSTEMIQUE A L'ETUDE DES KARSTS ET DU PRETRAITEMENT DES SERIES CHRONOLOGIQUES

Face aux contraintes associées à l'étude du fonctionnement hydrodynamique des karsts par des approches physiques ou conceptuelles, le choix de l'approche systémique s'est révélé être une alternative pertinente. Cette approche s'appuie sur l'hypothèse que les signaux, les séries chronologiques, d'entrée et de sortie du système contiennent suffisamment d'information pour identifier la transformation globale de l'entrée opérée par le système pour produire sa sortie.

Les karsts étant des systèmes non-linéaires, leur étude à partir des analyses, comme le spectre ou le corrélogramme, qui sont adaptées aux systèmes linéaires, nécessite de revisiter l'investigation « classique » au-delà des seuils statistiques de confiance comme le seuil 0,2 pour le corrélogramme.

L'étude des karsts, dans les domaines temporel (*réponse impulsionnelle*) et fréquentiel (*fonction de transfert*), permet de dégager des informations sur leur fonctionnement hydrodynamique et sur les processus qui y sont associés.

Les informations ainsi obtenues peuvent aussi être utilisées pour orienter la décomposition des séries brutes afin d'en isoler des composantes temporelles représentatives de processus hydrodynamiques, identifiés de façon empirique, à partir de la réponse impulsionnelle et de la fonction de transfert.

D'autres informations, comme la contribution des processus supposés à la genèse du débit à l'exutoire, peuvent être estimées grâce à l'utilisation de ces composantes pour alimenter les modèles de réseaux de neurones qui sont présentés dans le chapitre qui suit pour simuler ou prévoir le débit à partir du signal de pluie.

# 3. L'APPRENTISSAGE STATISTIQUE POUR L'ETUDE ET LA MODELISATION DES SYSTEMES NON-STATIONNAIRES

## 3.1. INTRODUCTION

Les hydrosystèmes karstiques ont un fonctionnement hydrodynamique extrêmement complexe, non-linéaire et potentiellement non-stationnaire (Chapitre 1). Or, leur caractérisation complète *in situ* étant quasi impossible, la méthodologie d'étude retenue est donc une approche plus globale, l'approche systémique (Chapitre 2). Ces méthodes permettent d'acquérir de l'information sur les relations linéaires entre les entrées et la sortie. De plus, ces analyses sont effectuées sous l'hypothèse d'invariance du système, de stationnarité, qui est erronée. Il semble donc nécessaire d'utiliser d'autres outils capables de prendre en compte la non-linéarité et la non-stationnarité du fonctionnement hydrodynamique du karst. Pour ce faire, l'apprentissage statistique offre un champ de possibilités considérable. En effet, les réseaux de neurones ont fait leurs preuves dans le domaine de l'intelligence artificielle. Ces outils présentent l'avantage de pouvoir apprendre et généraliser le comportement des processus non-linéaires à partir d'exemples. C'est cette capacité qui est intéressante pour la modélisation hydrodynamique des aquifères karstiques. C'est-à-dire qu'avec une base de données suffisante, le modèle est capable d'apprendre la relation entrée-sortie du système.

La capacité des réseaux de neurones artificiels à représenter des hydrosystèmes était déjà soulignée il y a une quinzaine d'année (Maier & Dandy, 2000) et a été vérifiée depuis. Or, ces outils présentent, pour la communauté des hydrologues, l'inconvénient d'être des modèles de type boîtes noires conçus de manière complètement déconnectées de la physique de ces systèmes. Les travaux récents (Johannet et al., 2008 ; Kong-A-Siou et al., 2013) ont permis : 1) de contraindre le réseau de neurones artificiels à partir des connaissances disponibles ; 2) d'extraire de l'information sur le fonctionnement hydrodynamique. Ce sont ces derniers points qui sont au cœur de ce travail de thèse. Un autre point important est la non-stationnarité des hydrosystèmes karstiques qu'il est nécessaire de pouvoir prendre en compte du fait de leur évolution. Pour ce faire, il est possible d'utiliser des méthodes comme l'adaptativité ou encore l'assimilation de données très répandue en météorologie ou en océanographie. Ce type d'ajustement en « temps réel » est implémenté dans le modèle de façon novatrice dans des contextes différents (taille du bassin, type de non-stationnarité).

Ce chapitre aborde donc, dans un premier temps, la présentation des réseaux de neurones artificiels en tant que modèle non-linéaire capable de fournir des informations sur le fonctionnement hydrodynamique du karst. Cette partie du chapitre est composée d'un article, paru dans la revue *Karstologia* (Johannet et al., 2012b), et d'un complément d'information et de formalisation relatif aux méthodes utilisées.

Dans un second temps, ce sont les méthodes d'adaptation des modèles de réseaux de neurones aux non-stationnarités qui sont abordées au travers d'un article en cours de publication dans *Hydrological Sciences Journal* (Taver et al., 2014). L'article est introduit, puis complété, afin d'assurer une meilleure compréhension et une transition vers l'application à l'hydrosystème du Lez.

## 3.2. LES RESEAUX DE NEURONES POUR L'ETUDE, LA MODELISATION ET LA PREVISION DU FONCTIONNEMENT HYDRODYNAMIQUE DU KARST

### 3.2.1. PREAMBULE

Cet article a été publié en vue de présenter aux lecteurs à sensibilité naturaliste (spéléologues, géographes, ...) les capacités de la modélisation par réseaux de neurones. Du fait du public ciblé, certains concepts nécessitant une formalisation mathématique plus développée et homogénéisée avec ce qui est présenté dans la suite de ce travail sont présentés après l'article.

### 3.2.2. ARTICLE SUR L'APRENTISSAGE STATISTIQUE POUR LA MODELISATION DES HYDROSYSTEMES KARSTIQUES

# Les réseaux de neurones artificiels pour la modélisation hydrodynamique des aquifères karstiques : présentation générale et illustrations.

## Artificial neural networks for hydrodynamic modeling of karst aquifers: overview and illustrations.

Anne Johannet<sup>1</sup>, Virgile Taver<sup>1,2</sup>, Line Kong-A-Siou<sup>3</sup>, Valérie Borrell Estupina<sup>2</sup>, Séverin Pistre<sup>2</sup>, Alain Mangin<sup>4</sup>, Bernard Vayssade<sup>1</sup>, Marc Vinches<sup>1</sup>, Dominique Bertin<sup>5</sup>

Ecole des Mines d'Alès, LGEL, 6 av de Clavières 30 3019 Alès Cedex, France

UM2 - Hydrosociences, 2 Place Eugène Bataillon, 34095 Montpellier Cedex 5 France

ENSEGID, 1 Allée François Daguin, 33607 Pessac, France

Station d'Écologie Expérimentale, 09200 Saint-Girons, France

GEONOSIS, 51 place Roger Tribes, 30140 Saint-Jean-du-Pin, France

### **Abstract**

Karst aquifers provide fresh water for 20% to 25% of the global population. Around the Mediterranean Sea, they are sometimes considered as natural water towers or as dams, able to minimize flooding. The high level of heterogeneity found in such aquifers and the difficulties encountered in delimiting their subterranean feed basin make it a challenge to fully understand their hydrological behavior, and accurately simulate and forecast their evolution. In this context, this article presents how hydrodynamic modeling of karst aquifers can be usefully performed using a new approach issued from machine learning: neural networks. Thanks to an automatic way to calculate their parameters, called learning, neural networks can model unknown functions using representative database. Increasingly used in hydrology, neural networks are first introduced in this article to perform discharge simulation and flood forecasting. The training ability of neural networks is given in the framework of the systemic paradigm, not only restricted to black box modeling, but also to increase information related to the basin behavior (time transfer and water origin). Illustrations are provided on two well-known French karst basins: the *Baget (Ariège)* and the *Lez (Hérault)*, both associated with extensive datasets.

**Keywords:** karst, hydrodynamic modeling, neural networks, machine learning, KnoX

### **Résumé en français**

Les aquifères karstiques permettent d'alimenter en eau potable près de 25% de la population mondiale. Sur le pourtour méditerranéen, ils sont considérés parfois comme des châteaux d'eau naturels ou bien comme des barrages écrêteurs de crue. Ces propriétés remarquables, stimulantes de par les enjeux soulevés sont cependant difficiles à quantifier et à appréhender objectivement du fait de la complexité du karst, due à une forte hétérogénéité de structure induisant également des non-linéarités. Dans ce contexte cet article propose d'aborder la modélisation hydrodynamique des karsts par une nouvelle approche appartenant à



l'apprentissage statistique : les réseaux de neurones artificiels. Ces derniers sont des modèles mathématiques issus de l'intelligence artificielle qui peuvent identifier toute fonction dynamique non linéaire au moyen d'un apprentissage. Ils sont ainsi parfaitement à même de modéliser les fonctions inconnues des aquifères karstiques pourvu que l'on dispose d'une base de données. Très utilisés en hydrologie et appliqués également à la modélisation hydrodynamique des aquifères karstiques, les réseaux de neurones sont tout d'abord abordés dans cet article pour effectuer des fonctions de prévision des crues ou de simulation de débit. Leur capacité d'apprentissage est présentée dans le cadre du paradigme systémique, non seulement pour réaliser la fonction de boîte noire, mais également pour améliorer la connaissance sur les aquifères karstiques. Ainsi, l'origine des eaux et les temps de transferts peuvent être mieux appréhendés grâce à une méthodologie originale.

Cet article présente les études menées sur deux bassins karstiques bien connus, et disposant de nombreuses données de pluie et de débit : le Baget (Ariège) et le Lez (Hérault).

**Mots clés :** karst, modélisation hydrodynamique, réseaux de neurones, apprentissage statistique, KnoX

### ***Introduction : l'apprentissage statistique pour la modélisation hydrodynamique***

*"Si les gens ne croient pas que les mathématiques sont simples, c'est seulement parce qu'ils ne réalisent pas combien la vie est compliquée !" (J. Von Neumann, cité par F. L. Alt, 1972).*

Comme énoncé par John Von Neumann, le père de l'ordinateur qui imagina nombre de leurs applications dans les années 1940, une des difficultés de la conception de systèmes modélisant les milieux naturels est la complexité extrême de ces systèmes, qui nous paraissent pourtant parfois si simples. Si l'on se risquait à vouloir décrire complètement et exhaustivement toutes les situations que peut rencontrer un bassin versant, ceci nous amènerait à lister et expliciter toutes les fonctions de ce système. Il apparaîtrait assez rapidement que cette tâche dépasserait les capacités humaines. L'approche algorithmique qui a nourri les systèmes experts à leurs débuts a ainsi montré ses limites, non seulement parce que toutes les configurations possibles ne peuvent être décrites, car elles sont trop nombreuses, mais également parce que l'information utile n'est pas forcément disponible sous une forme accessible par des mesures.

Tentons par exemple de modéliser le fonctionnement hydrologique d'un bassin karstique. À supposer que l'on connaisse les modèles physiques des multiples phénomènes permettant de réaliser la transformation de la pluie en débit dans le réseau fissural et les drains, est-il réellement possible d'obtenir toutes les informations utiles à la description des phénomènes physiques qui opèrent dans la transformation pluie-débit ? Pour ne parler que de la part souterraine, et si tant est que l'on puisse le faire de manière non destructive, doit-on, par une multitude de forages, mesurer l'exakte épaisseur de chaque type de sol ou de roche, ainsi que son pendage, sa densité de fractures ou de vides ?

L'apprentissage statistique apporte une réponse à ces questions car il se fonde sur l'erreur effectuée par le modèle par rapport à l'objectif qui lui est imposé. Ainsi, grâce à une décomposition de la tâche à réaliser sur une base de fonctions paramétrées, l'apprentissage statistique permet simultanément de déterminer la fonction du modèle ainsi que de fixer ses paramètres, de manière à minimiser l'erreur sur un *ensemble d'apprentissage* donné. L'apprentissage n'est donc pas seulement le calage des paramètres d'un modèle, l'apprentissage *construit* le modèle en même temps qu'il *calcule* ses paramètres.

Le "côté obscur" de l'apprentissage statistique est que la décomposition sur une base de fonctions paramétrées n'est pas très interprétable, au sens de la connaissance sur les phénomènes physiques ; c'est pourquoi ces modèles issus de l'apprentissage statistique sont qualifiés de "boîtes noires", et parfois décriés comme étant trop complexes à mettre en œuvre et "invérifiables". Pourtant les modèles de type *boîte noire* extraient des bases de données une grande quantité d'information. Autant pour asseoir leur validité que pour exploiter cette information, certains travaux s'intéressent aux méthodes permettant de recouvrer cette connaissance ; ainsi les *boîtes transparentes* qui sont présentées dans cet article en section IV appliquent des contraintes au réseau de neurones afin de restreindre le champ des possibles et de pouvoir dégager une interprétation du calcul effectué par les fonctions paramétrées.

Sachant qu'une partie du lectorat de *Karstologia* n'est pas familiarisée avec une approche très formelle nous demanderons à ces lecteurs de bien vouloir se laisser entrainer sans *a priori* dans la lecture de cet article que nous allons tenter de rendre accessible à tous les publics curieux intéressés. Nous vous proposons de commencer la lecture, dans la section II, par l'illustration de la modélisation de la relation pluie-débit par un modèle linéaire. La difficulté que rencontre ce modèle à représenter à la fois les crues et les étiages nous amènera à proposer une autre approche fondée sur l'apprentissage statistique pour résoudre un problème non-linéaire à l'aide d'une fonction de coût et d'une base d'exemples. Nous nous intéresserons ensuite au dilemme biais-variance, que l'on pourrait présenter comme une formulation statistique du *principe du rasoir d'Occam*<sup>1</sup>, et qui conduit à sélectionner le modèle neuronal afin d'assurer une bonne qualité de généralisation. Nous pourrions alors présenter les modèles de prédicteur les plus adaptés à la modélisation des systèmes karstiques, qui nous intéressent particulièrement.

Hétérogènes par nature, les bassins karstiques n'ont rien de ce qui rend belle la physique : l'invariance d'échelle et la symétrie. Cumulant souvent une géologie complexe et une fracturation dont l'hétérogénéité naturelle est renforcée par la karstification, les systèmes karstiques, spécialement en montagne ou sur le pourtour méditerranéen, sont de plus soumis à des forçages météorologiques très mal connus et souvent imprévisibles. Alimentant près du quart de la population mondiale en eau douce et considérés comme les châteaux d'eau de la méditerranée, les aquifères karstiques peuvent jouer à la fois le rôle de soutien d'étiage et de barrage écrêteur de crue. Les enjeux qui leurs sont associés sont donc considérables. Deux bassins tests ont été choisis pour illustrer nos travaux sur la modélisation hydrodynamique des aquifères karstiques : le bassin du *Baget*, situé en *Ariège (France)* et le bassin du *Lez* situé dans *l'Hérault (France)*. Tous deux seront présentés en section III de cet article et les travaux de modélisation destinés à prévoir ou simuler leurs crues ainsi que leurs étiages seront présentés en section IV.

Disposer de modèles efficaces est évidemment essentiel lorsque l'on travaille sur de tels enjeux, mais *comprendre* ces modèles ou les utiliser pour mieux *connaître* les processus naturels est encore plus passionnant ; c'est le défi évoqué dans la cinquième et dernière partie de cet article. Nous y présentons comment l'on peut esquisser des modèles semi-physiques ou comment, grâce à l'intégration de connaissances dans l'architecture du réseau de neurones, cette dernière peut être contrainte pour, en retour, permettre d'en extraire de l'information. Nos travaux sur le

---

<sup>1</sup> Guillaume d'Occam vécut au XIV<sup>ème</sup> siècle, il énonça le principe suivant : "*pluralitas non est ponenda sine necessitate*", qui signifie qu'il ne faut pas multiplier les hypothèses si elles ne sont pas nécessaires. Le principe du rasoir d'Occam fut formulé par la suite sous une forme plus prosaïque (et ironique) : pourquoi faire simple quand on peut faire compliqué ?

système karstique du Lez, qui cumule les difficultés d'une hétérogénéité géologique, d'une hétérogénéité pluviométrique, d'une anthropisation des débits par un pompage intense et d'un bassin à géométrie variable en fonction du niveau du remplissage, ont permis non seulement d'obtenir un modèle prédictif convenable, mais en plus d'estimer les transits d'eau souterraine entre les différents compartiments du karst et la source.

### **Deux bassins karstiques test : le Baget et le Lez**

#### **Le Baget**

Le karst du Baget est un karst pyrénéen bien connu (Mangin 1970) et pour lequel nous disposons d'une base de mesures importante. Le bassin du Baget (Ariège) a une superficie de 13,25 km<sup>2</sup> et comporte environ 1/3 de superficie non calcaire. C'est un karst d'altitude moyenne 950 m et de pluviométrie importante : plus de 1500 mm d'eau en moyenne annuelle sur la période d'étude (1973 à 2000), avec une évapotranspiration annuelle estimée à 540 mm. La rivière du Baget (photo 1), comme la plupart de ses homologues pyrénéennes a un étiage prononcé en automne et des crues importantes en décembre et au printemps. Compte tenu de l'altitude moyenne, le stockage d'eau sous forme de neige est assez faible et la fonte des neiges ne donne pas lieu à des crues importantes.



**Photo 1 : ruisseau du Baget en aval de Las Hountas, (photo : Anne Johannet)**

L'eau tombant sur le bassin versant du Baget peut, d'amont en aval : ruisseler sur des terrains non calcaires, puis se perdre par infiltration ou dans des pertes du ruisseau de Lachein (Figure 1) : perte de la Péreyre, perte de la Hille), alimentant ainsi le «Baget souterrain». En aval du vallon souvent asséché de Lachein, l'exutoire principal du système karstique du Baget est la source de Las Hountas. Lorsque le ruisseau est en crue, la perte de La Péreyre fonctionne en résurgence.

La base de données utilisée possède les mesures journalières de débit en aval de la source de Las Hountas du 31 août 1973 au 30 décembre 1999, ainsi que les données pluviométriques journalières mesurées à la station de Balagué pour la même période.

Grâce à la base de données, deux modélisations ont pu être réalisées à partir des réseaux de neurones formels : d'une part la simulation de la relation pluie-débit sur une année complète, et d'autre part la simulation des événements de crue (Johannet, 2008a).

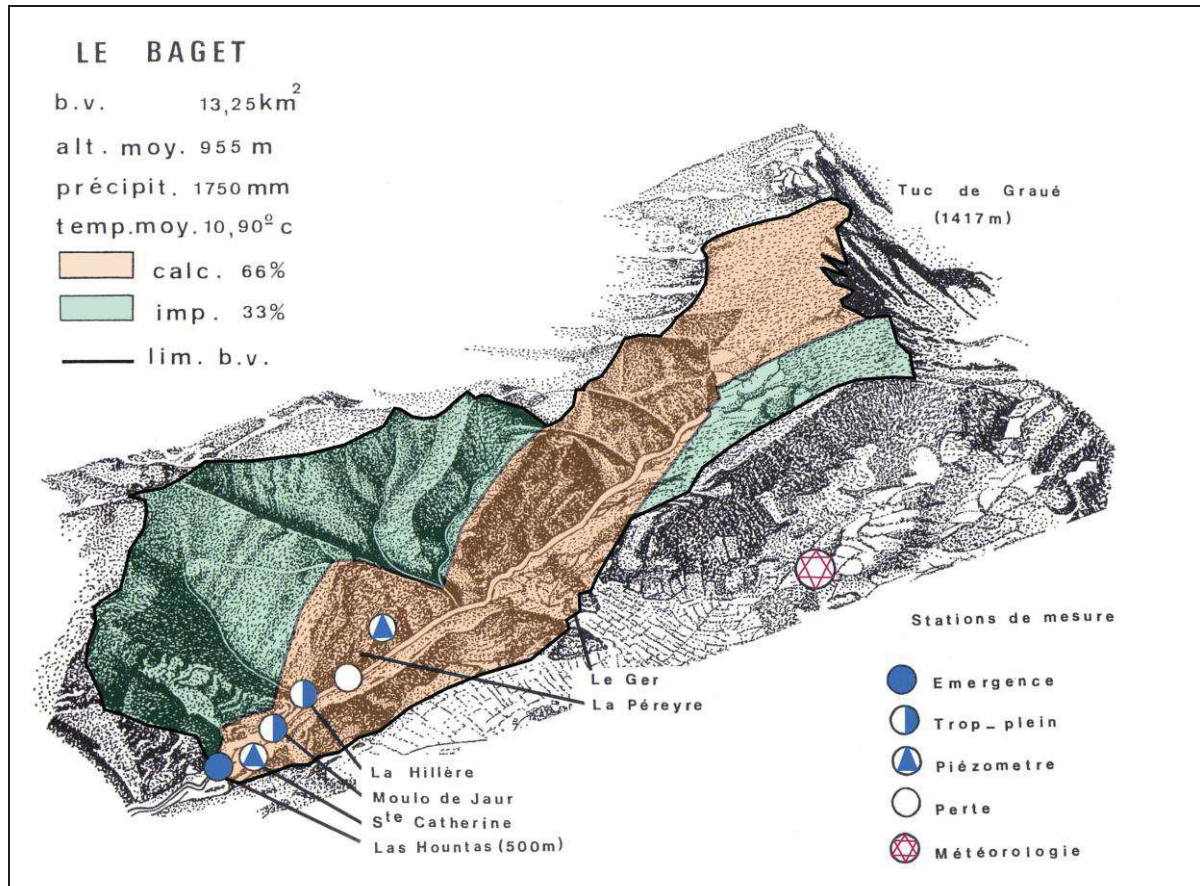


Figure 1 : Bassin versant du Baget (d'après Rouch, 1982). Baget catchment (from Rouch, 1982)

### Le lez

Le karst du Lez (Hérault) est un aquifère méditerranéen très étudié depuis les années 1970 (Marjolet et Salado, 1976 ; Paloc, 1979), du fait de l'important réservoir en eau qu'il représente et de la proximité de la ville de Montpellier, qui connaissait à l'époque une croissance démographique forte. L'exutoire principal de ce karst, la source du Lez (photo 2), est exploité par pompage directement dans le drain karstique depuis 1982, ce qui a pour effet d'assécher la source en période d'étiage. Une Déclaration d'Utilité Publique impose un débit de pompage maximum de 1700 l/s et un rabattement maximum de 30m dans le piézomètre proche du pompage. Enfin, le débit réservé minimum est de 160 l/s dans la rivière. Ainsi, lorsque la source est à sec, un débit de 160 l/s minimum est restitué à la rivière. Le débit de la source du Lez est mesuré en aval de cette restitution. Le débit mesuré est donc la somme du débit naturel et du débit restitué. Une telle exploitation est rendue possible par la spécificité du climat méditerranéen, très sec en été, mais très humide à l'automne (40% des précipitations annuelles tombent entre septembre et novembre). Les pluies intenses d'automne permettent donc la

recharge de l'aquifère qui a été surexploité durant l'été. La recharge ainsi effectuée permet de plus de mitiger les crues d'automne (Borrell-Estupina, 2014), (Fleury, 2011).



**Photo 2 : Source du Lez, (photo : Bernard Vayssade)**

Le bassin hydrogéologique de la source du Lez est estimé à 400 km<sup>2</sup> environ (Fleury, 2008). Ces limites de bassins (Figure ) ont été proposées à partir de la compilation d'études antérieures. L'aquifère principal du Lez est constitué de calcaires d'âge jurassique moyen, il est captif sur une grande partie du bassin et libre au Sud-Ouest (Causse de Viols-le-Fort). Le bassin comporte également des karsts perchés, qui ne sont pas en relation directe avec le karst principal. Les niveaux géologiques sont affectés par de nombreuses failles, généralement orientées Sud-Ouest Nord-Est. Ces failles ont essentiellement joué en décrochement puis en faille normale, elles constituent une zone d'infiltration et de circulation préférentielle de l'eau. La faille de Corconne qui traverse le bassin du Sud-Ouest au Nord-Est peut également faire office de barrage aux écoulements, en particulier dans sa partie Sud qui met en relation les terrains karstifiés situés à l'Ouest avec des terrains peu perméables situés à l'Est (Figure 2)(Bérard, 1983, Karam, 1989).

Le système karstique du Lez a été découpé en 4 zones, fondées sur le croisement entre le contexte hydrogéologique connu et les propriétés du bassin de surface (Kong-A-Siou, 2011a). Ci-dessous, voici résumées les considérations qui nous ont permis d'aboutir à ce découpage, qui nous sera utile dans la partie V-a), le lecteur intéressé trouvera de plus amples informations sur l'hydrosystème Lez dans un prochain numéro spécial de Karstologia (numéro spécial Lez):

la faille de Corconne apparaît comme une limite évidente entre la partie Est et la partie Ouest du bassin. Il faut rappeler que cette faille met en relation des niveaux karstifiés avec des niveaux marneux peu perméables ce qui constitue un frein à l'écoulement entre les parties Est et Ouest du bassin. De plus elle constitue une zone d'infiltration privilégiée grâce à la présence de nombreuses pertes le long de la faille (photo 3).

La zone d'affleurement des terrains tertiaires au sud du bassin constitue une zone particulière pour l'infiltration car ces terrains sont très peu perméables (conglomérats). L'aquifère est ici

captif, recouvert par plusieurs centaines de mètres de terrains dont certains sont très peu perméables.

Le Causse de Viols le Fort, où affleurent presque exclusivement les terrains aquifères est également identifié comme une zone homogène en terme de recharge de l'aquifère principal. L'infiltration se fait directement dans les calcaires du jurassique qui présentent une karstification bien développée sur le Causse. Cette zone constitue donc une zone d'infiltration, délimitée à l'Est par la faille de Corconne et au Nord par le ruisseau du Terrieu.

Enfin, le Causse de l'Hortus, aquifère perché séparé de l'aquifère principal par les marnes du Valanginien (Crétacé supérieur) constitue la dernière zone. La limite Est correspond à la faille de Corconne et la limite Sud au ruisseau du Terrieu (photo 4).

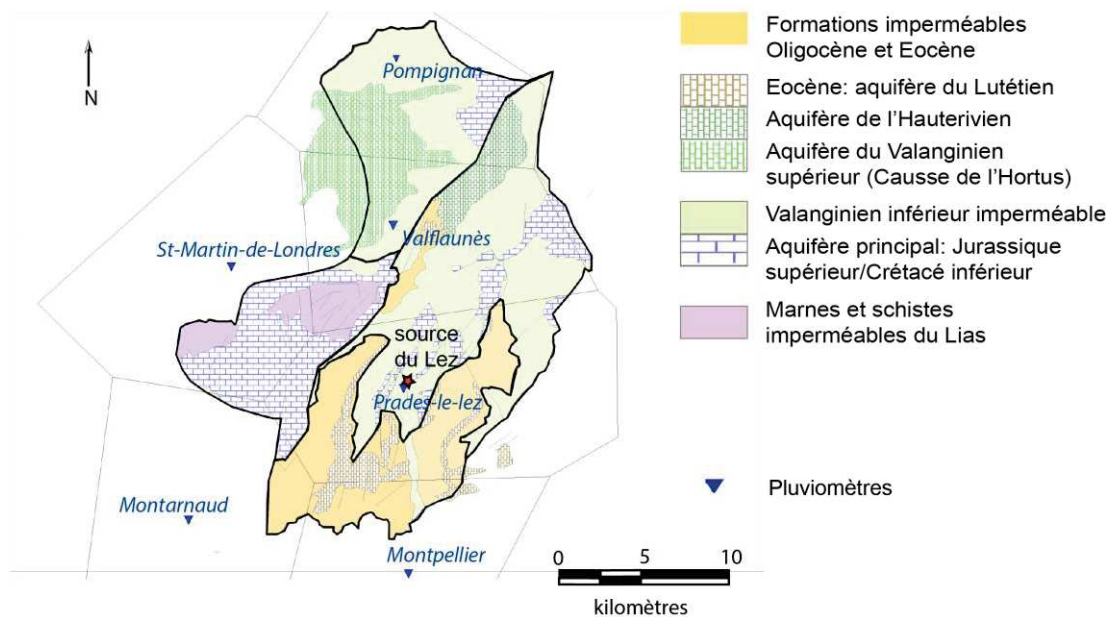


Figure 2 : Bassin hydrogéologique de la source du Lez (Kong-A-Siou, 2011a). *Lez spring hydrogeological catchment*



Photo 3 : perte dans le Brestalou de Claret au niveau de la faille de Corconne, (photo : Anne Johannet)



Photo 4 : Pic-St-loup (gauche) et Causse de l'Hortus (droite), (photo : Anne Johannet)

## ***Les réseaux de neurones formels***

### ***Définitions***

#### ***(i) Apprentissage***

L'apprentissage consiste à estimer le vecteur  $\theta$  des paramètres des fonctions paramétrées (appelées neurones) du réseau de neurones afin de minimiser un critère préalablement défini. Ce critère, encore appelé *fonction de coût*, est généralement l'erreur quadratique moyenne. Comme le modèle neuronal est non linéaire en ses paramètres, la fonction de coût n'est pas quadratique en ses paramètres et la méthode des moindres carrés n'est donc pas applicable. Des méthodes de minimisation itératives de la fonction de coût sont donc utilisées. Le lecteur intéressé pourra trouver de plus amples informations sur les méthodes de calcul itératives des paramètres, appelées *règles d'apprentissage*, dans (Dreyfus *et al*, 2008) ; il suffit d'indiquer ici que la règle la plus efficace est actuellement la règle de Levenberg-Marquardt, que nous avons utilisée dans tous nos travaux récents, qui est une règle de gradient du second ordre faisant appel à l'inversion d'une matrice approchée de la matrice Hessienne (Bender *et al*, 1996), (Press *et al*, 1992). Cette méthode est avantageuse car bien qu'appartenant à la catégorie des méthodes de second ordre, elle ne nécessite pas le calcul des dérivées secondes de la fonction de coût.

#### ***(ii) Modèles de neurones et architectures***

Les réseaux de neurones constituent une famille de modèles conçus par apprentissage statistique. La base de la non linéarité des modèles neuronaux est la fonction *neurone*, cette dernière est une fonction algébrique non linéaire, paramétrée et à valeur bornée de ses variables d'entrées, le vecteur  $x$  :

$y=f(\mathbf{x},\boldsymbol{\theta})$ , où  $\mathbf{x}$  et  $\boldsymbol{\theta}$  sont respectivement les vecteurs des variables et des paramètres de la fonction neurone.

Le neurone formel effectue deux actions :

le calcul de son *potentiel*  $v$ , ou somme pondérée de ses variables d'entrée par ses paramètres :  
 $v=\mathbf{x}\cdot\boldsymbol{\theta}$ ,

le calcul de sa sortie  $y$  par une fonction d'évaluation qui est non linéaire ou parfois linéaire :  $f(\cdot)$ .

La fonction d'évaluation est généralement une fonction à seuil qui peut être continue et dérivable comme la fonction tangente hyperbolique, ou discontinue dans le cas de la fonction de Heaviside (fonction seuil).

Grâce aux modèles de neurones précédemment définis, un réseau de neurones peut être conçu en connectant les neurones les uns aux autres grâce à une *architecture*. Parmi toutes les architectures proposées, le réseau appelé *perceptron multicouche* sera particulièrement utilisé ; nous l'appellerons dans la suite plus simplement réseau. Ce réseau est composé d'une couche de neurones non linéaires de type sigmoïde, dite *couche cachée* car il n'y a pas de grandeur observée correspondant aux sorties de ces neurones, et d'une couche de sortie composée dans nos études d'un seul neurone.

Notons que le réseau tel que représenté en Figure 3 ne possède pas de rétroaction (bouclage) de sa sortie vers ses entrées il est donc appelé *réseau statique* ou *non-récurrent*.




Figure 3 : Réseau Perceptron Multicouche, les ronds représentent les neurones, les carrés les variables, les flèches correspondent aux paramètres.

**Multilayer Perceptron.** Rings correspond to neurons, squares correspond to variables and arrows correspond to parameters

### (iii) Identification universelle et parcimonie

K. Hornik *et al.* ont démontré que le perceptron multicouche possédait la propriété d'approximation universelle (Hornik *et al.*, 1989). C'est-à-dire que toute fonction  $g(\mathbf{x})$ , à valeurs bornées dans un domaine défini, peut être approchée à la précision  $\epsilon$  près dans ce domaine par un réseau de type multicouche possédant un nombre fini de neurones cachés. C'est sur cette propriété que nous fondons le choix d'utiliser le perceptron multicouche pour identifier les relations non linéaires des systèmes karstiques que nous étudions. Bien entendu, la capacité à trouver la solution dépendra tout autant de la base des informations disponibles que de la méthode de calcul des paramètres.

Or, la capacité d'identification universelle a son prix, c'est celui de l'augmentation du nombre de paramètres libres du modèle qu'il faut ajuster. Opérant sur des fonctions non linéaires (les fonctions paramétrées neurones), ces paramètres permettent au modèle de s'ajuster parfaitement à l'ensemble d'apprentissage, et d'autant plus efficacement que le nombre de ces paramètres, ou la complexité du modèle, croît. Mais le modèle, si certaines précautions ne sont



pas prises, peut alors être *surajusté* et tellement spécialisé par rapport à l'ensemble d'apprentissage qu'il apprendrait même la réalisation particulière du bruit dans cet ensemble et serait alors incapable de généraliser à d'autres ensembles. Le dilemme biais-variance, présenté ci-après formalise ce phénomène.

### ***Le piège du sur-apprentissage***

#### ***(i) Dilemme biais-variance***

Le but du modèle construit par apprentissage statistique est d'estimer la fonction  $g(\mathbf{x})$  par une fonction  $g_m(\mathbf{x})$ , au mieux, compte-tenu des observations disponibles. L'erreur de prédiction théorique réalisée par le modèle a été estimée par S. Geman (Geman *et al.*, 1992) qui a montré que cette erreur peut s'exprimer sous la forme de la somme de trois termes. Le premier des trois termes correspond au bruit (irréductible présent dans les observations), le second terme est appelé *biais*, il transcrit comment l'espérance mathématique de la prévision est éloignée de l'espérance mathématique théorique, tandis que le troisième terme est la *variance*, il rend compte de la variance de la prédiction, en fonction des modèles obtenus avec tous les ensembles d'apprentissage possibles. Le biais correspond à l'ajustement du modèle aux données d'apprentissage et la variance est la variabilité de la prédiction obtenue en fonction de ces différents ensembles.

Plusieurs observations peuvent être faites sur cette formulation proposée par Geman, d'une part les trois termes sont positifs, l'erreur de prédiction ne peut donc en moyenne être inférieure à celle des données d'observations ; d'autre part, le biais et la variance varient en sens inverse l'un de l'autre en fonction de la complexité du modèle. Ainsi lorsque la complexité du modèle augmente, le biais diminue car le modèle s'adapte d'autant plus facilement aux données d'apprentissage qu'il est plus complexe. Par ailleurs la variance du modèle augmente avec la complexité car la variabilité des prédictions obtenues est de plus en plus sensible aux spécificités de l'ensemble d'apprentissage et même à la réalisation particulière du bruit dans cet ensemble.

La somme des deux termes, variance et biais, présente donc un minimum qu'il convient de rechercher en fonction de la complexité. Au delà de ce minimum, le modèle est dit *surajusté*.

Même si le dilemme biais-variance ne s'applique en toute rigueur que dans la limite des grands ensembles de données, et si certains travaux se sont déjà intéressés à estimer les deux termes de biais et variance (Gallinari et Cibas, 1999), nous avons souhaité illustrer le dilemme biais-variance sur un système hydrologique particulier : le bassin versant du Baget dans les Pyrénées Ariégeoises. Ce bassin versant a été choisi car c'est celui pour lequel nous disposons de la plus grande base de données. Celle-ci comporte de manière journalière, les précipitations à la station pluviométrique de Balagué et les débits de la petite rivière du Baget, de 1973 à 2000 soit près de 9800 valeurs de chaque variable. La base de données disponible a été partagée en deux sous-ensembles, d'une part celui dédié à l'apprentissage et d'autre part celui dédié au test, ce dernier comportant les deux dernières années de la base soit les années 1999 et 2000. Plusieurs sous-ensembles d'apprentissage ont été composés afin d'établir autant de modèles et pour calculer ainsi les deux termes du biais et de la variance. Chaque ensemble d'apprentissage comporte l'ensemble des valeurs d'apprentissage sauf deux années consécutives qui en sont retirées. Successivement sont ainsi retirées toutes les années de la base d'apprentissage et 14 ensembles d'apprentissage sont ainsi définis. L'espérance mathématique est alors approchée par la moyenne effectuée sur les 14 modèles ainsi constitués.

Une autre difficulté subsiste : la valeur de la régression apparaissant dans le terme de biais n'est pas connue. Néanmoins, afin d'effectuer les calculs nous l'approchons par la valeur mesurée du débit tout en sachant que cette valeur n'est pas parfaite puisqu'elle comporte le bruit de mesure qui peut être très important pour ce type de grandeur (20% ou 30% sont souvent cités pour les grands débits).

Les termes approchés de biais et de variance calculés sont donc :

$$\text{Biais} : (y^p(\mathbf{x}) - \text{Moy}_{\mathcal{A}}[y(\mathbf{x}, \mathcal{A})])^2$$


$$\text{Variance} : \text{Moy}_{\mathcal{A}}[(y(\mathbf{x}, \mathcal{A}) - \text{Moy}_{\mathcal{A}}[y(\mathbf{x}, \mathcal{A})])^2]$$

$y^p(\mathbf{x})$  est la valeur observée du débit,  $y(\mathbf{x}, \mathcal{A})$  est la valeur estimée du débit par le modèle conçu avec l'ensemble d'apprentissage  $\mathcal{A}$ ,  $\text{Moy}_{\mathcal{A}}[y(\mathbf{x}, \mathcal{A})]$  est la moyenne effectuée sur le débit estimé par les modèles conçus grâce aux différents ensembles d'apprentissage.

On pourra trouver en **Figure** les évolutions du biais et de la variance en fonction du nombre de paramètres libres du modèle. Ce dernier indicateur a été choisi pour mesurer la complexité du modèle car même s'il est généralement admis qu'il n'est pas le plus représentatif pour les modèles non linéaires, il est cependant souvent utilisé, ne serait-ce que du fait de sa simplicité.

Tout d'abord on pourra noter que le biais et la variance ont des ordres de grandeur très différents de ce que nous avons pu noter dans la littérature, ( $10^{-1}$  ou  $10^{-2}$ ) ; de plus, les deux termes de biais et de variance ont ici un ordre de grandeur de différence l'un par rapport à l'autre alors qu'ils sont du même ordre pour les illustrations dont nous disposons (Geman *et al*, 1992), (Gallinari et Cibas, 1999). La première remarque peut être expliquée par les progrès faits depuis dans les algorithmes d'apprentissage. Pour la seconde constatation, nous pensons que le biais est très important dans les applications hydrométéorologiques du fait des grandes incertitudes et bruits sur les mesures ; de ce fait, l'approximation du terme  $g(\mathbf{x})$  par  $y^p(\mathbf{x})$  est vraisemblablement assez inexacte.

On peut noter de plus sur cette illustration que le biais décroît bien au début tandis que la variance augmente globalement régulièrement en fonction de la complexité. Si la diminution du biais est rapide au début, en revanche ce dernier oscille pour les valeurs moyennes de complexité puis se met à augmenter pour les complexités élevées. Nous pensons que ce comportement du biais est dû aux incertitudes et au bruit de mesure qui l'entachent vraisemblablement d'une erreur liée à la variance.



**Figure 4 : Evolution du biais (trait pointillé) et de la variance (trait continu) en fonction du nombre de paramètres libres du modèle.**

**Bias (dotted line) and variance (dashed line) evolution versus the number of free parameters**

**(ii) Mise en évidence du sur-apprentissage sur le bassin karstique du Lez**

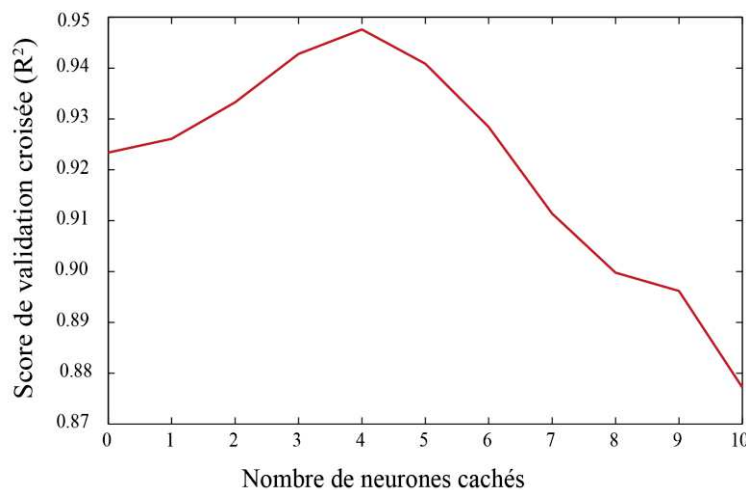
Le phénomène de sur-apprentissage va être mis en évidence sur le modèle destiné à simuler le débit à la source du Lez au pas de temps journalier. Deux types de variables sont introduits en entrée du modèle : la pluie mesurée à la station de St-Martin-de-Londres (*variable exogène*), le débit de la source du Lez mesuré pour les pas de temps précédents. Comme le débit appliqué en entrée est le débit mesuré, il peut être considéré comme une variable exogène, au même titre que la pluie.

Nous allons présenter ici une partie des résultats obtenus concernant la sensibilité du modèle à l’augmentation exagérée de la complexité du modèle (en particulier le nombre de neurones cachés). Les résultats complets de cette étude ont été publiés dans (Kong-A-Siou *et al.* 2012).

Dans l’exemple suivant, représenté en **Figure** nous reportons le score de qualité du modèle (basé sur le critère de Nash), ou score de validation croisée (Kong-A-Siou *et al.* 2012), en fonction du nombre de neurones cachés utilisé. Le critère de Nash, ou  $R^2$  (Nash et Sutcliffe, 1970) permet d’évaluer la qualité des modélisations, il est calculé selon l’équation suivante :

$$R^2 = 1 - \frac{\sum_{k=1}^n (y^p(k) - y(k))^2}{\sum_{k=1}^n (y^p(k) - \bar{y}^p)^2}$$

où  $y^p$  est la sortie observée du processus,  $y$  est la sortie estimée par le modèle,  $k$  est le temps discret et  $n$  le nombre d’échantillons sur lesquels est calculé le critère.




**Figure 5 : Score de validation croisée en fonction du nombre de neurones cachés.**

**Cross-validation score versus the number of hidden neurons**

La courbe illustre le phénomène de sur-apprentissage que nous avons évoqué au paragraphe précédent. Le modèle optimal est obtenu lorsque le score est maximal, c’est à dire pour 4 neurones cachés. Si le nombre de neurones cachés est supérieur, le modèle a une grande souplesse ce qui lui permet de très bien s’adapter aux données d’apprentissage mais aussi au bruit qu’elles contiennent. Son erreur en généralisation à un ensemble de validation inconnu devient alors grande ce qui fait chuter le score de validation croisée. L’hydrogramme obtenu

pour un nombre trop grand de neurones cachés (Figure 6-a) illustre bien le dilemme biais variance : la variance est importante et nuit à la qualité du modèle.

L'hydrogramme de simulation du débit du Lez obtenu pour le nombre optimal de neurones cachés est présenté en Figure 6-b. Cette simulation est très satisfaisante (le coefficient de Nash est de 0,95) et nous a encouragé à concevoir d'autres modèles, avec cette fois un horizon de prévision pouvant aller jusqu'à trois jours. Ces résultats sont présentés dans (Kong A Siou *et al.* 2011b) et montrent qu'une prévision de bonne qualité a pu être proposée jusqu'à un horizon de prévision de 2 jours.




**Figure 6: Hydrogrammes obtenus pour 8 neurones cachés (a) et 4 neurones cachés (b).**

**Hydrographs obtained with 8 hidden neurones (a) and 4 hidden neurones (b)**

### ***(iii) Sélection de variables pour optimiser la complexité***

Le nombre de paramètres d'un réseau de neurones est lié principalement au nombre de neurones cachés et au nombre de variables ; en effet chaque variable d'entrée étant liée à chaque neurone caché par un paramètre à calculer, le nombre de paramètres sur la première couche est égal à  $n_v$  (nombre de variables) multiplié par  $n_h$  (nombre de neurones cachés). La complexité du modèle dépend donc tout autant des deux grandeurs. Pour cette raison le domaine de recherches ayant trait à la sélection de variables est très actif en apprentissage statistique. Dans ce contexte, une approche originale a été proposée par Virgile Taver dans le cadre de sa thèse en cours pour l'hydrosystème du Lez. Dans ses travaux, V. Taver cherche à mettre en évidence les processus sous-jacents dans le système hydrologique afin de mieux dimensionner le modèle neuronal, et en particulier pour pouvoir représenter les processus liés à des composantes à long terme, par exemple les processus contribuant particulièrement au débit de base. Lorsque l'on applique les méthodes classiques de sélection de variables (Kong-A-Siou, 2011-b), les fenêtres temporelles de dimensionnement de l'historique de pluies à appliquer au modèle sont assez réduites (environ 10 jours selon de système étudié). Théoriquement, ces fenêtres peuvent permettre de prendre en compte les composantes à long terme, mais en pratique, on observe

que ces dernières sont mal appréhendées. Ainsi pour optimiser le nombre de paramètres sans enlever d'informations au modèle, l'idée est de regrouper les entrées de pluies selon plusieurs plages temporelles dont les valeurs sont déduites de la réponse impulsionnelle. Rappelons que la réponse impulsionnelle est la réponse du système à une impulsion, à la fois très intense et très courte. Cette impulsion peut représenter, par exemple, un orage très intense et très bref. Il est montré de manière théorique que cette réponse impulsionnelle est unique pour un système linéaire, c'est à dire un système décrit par une équation différentielle linéaire à coefficients constants. En revanche la réponse impulsionnelle n'est pas unique pour un système non linéaire car elle dépend de l'état de ce dernier : schématiquement la réponse à un orage n'est pas la même en crue ou en étiage. La première étape de la démarche est donc d'identifier sur la réponse impulsionnelle (calculée à partir du corrélogramme croisé pluie-débit) quels sont les différents processus sous-jacents identifiables par des ruptures de pente. Ceci est illustré pour le Lez sur la Figure 7. Quatre fenêtres temporelles sont identifiées. Et dans ce cas particulier, le réseau de neurones va recevoir en entrée 4 sommes, chacune correspondant à un des sous processus identifiés. La première somme couvre, dans ce cas, la période de  $j$  (jours actuel) à  $j-5$  ; la seconde de les pluies de  $j-6$  à  $j-8$  ; la troisième de  $j-9$  à  $j-14$  ; la quatrième de  $j-15$  à  $j-20$ . On note que la réponse impulsionnelle descend en deçà de la valeur de 0,2 signifiant que les sorties ne sont plus statistiquement *linéairement* corrélées aux entrées (Mangin, 1975). Cependant le réseau de neurone étant un modèle non-linéaire il est possible qu'il puisse tirer profit des variables d'entrées (pluies) pour les retards situés au delà de ce seuil de 0,2.



**Figure 7 : Figuration des différents processus impliqués pour constituer la réponse impulsionnelle du système. La courbe noire continue représente la réponse impulsionnelle du système, les différentes courbes pointillées représentent les contributions supposées de processus internes à l'hydrosystème. Elles interviennent à des temps de retard différents (abscisse) et sont ainsi associées à des temps de réponse différents.**

**Representation of the different processes involved in the impulse response. Black line is the system impulse response; dotted lines correspond to supposed contributions of internal processes. These processes take part according to different delays (abscissa) and are thus associated to different response time.**

Pour prendre en compte et expliciter ces différents processus, le réseau de neurones proposé n'est plus exactement le perceptron multicouches (tel que représenté en Figure ), mais comporte une couche supplémentaire de 4 neurones linéaires, chacun calculant la somme des entrées

correspondant au processus auquel il contribue. Ce modèle est représenté en **Figure** ; si l'on considère uniquement les paramètres directement connectés aux entrées de pluies, il comporte 32 paramètres contre 48 pour le réseau classique du perceptron multicouche. Le nombre de paramètres est donc inférieur et l'historique de pluies pris en compte permet de représenter des processus à plus long terme. Si l'on regarde ensuite les performances des deux modèles : le perceptron multicouche dimensionné classiquement pour minimiser le nombre de paramètres (noté PMC) et le réseau contraint par l'information issue de la réponse impulsionnelle (noté IANN, comme *Information constrained Artificial Neural Network*), on note sur la Table 1 que le second modèle est meilleur : la prise en compte des composantes à long terme a pu être réalisée tout en optimisant le nombre de paramètres grâce à l'introduction de contraintes dans le modèle.

|             |         | Nash ensemble de Test |
|-------------|---------|-----------------------|
| <b>ANN</b>  | moyenne | 0,67                  |
|             | médiane | 0,68                  |
|             | max     | 0,72                  |
| <b>IANN</b> | moyenne | 0,75                  |
|             | médiane | 0,76                  |
|             | max     | 0,79                  |

**Table 1 : Critères de Nash calculé sur les ensembles de test (modèle récurrent)**

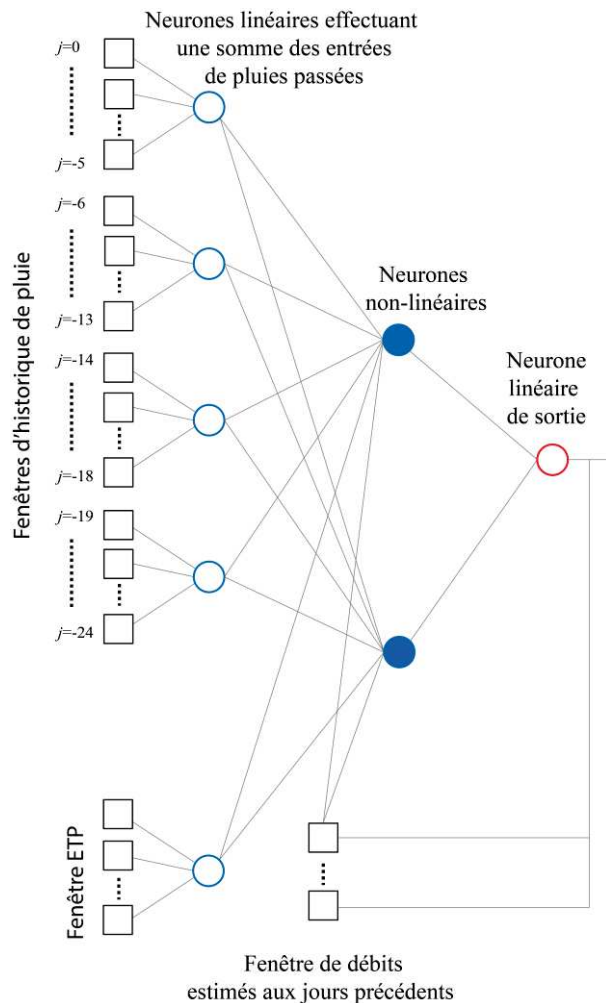


Figure 8 : Architecture du modèle AINN (Information constrained Artificial Neural Network). La variable d'entrée ETP sera explicitée par la suite (paragraphe IV.b).

Model AINN (Information constrained Artificial Neural Network). The input variable ETP is explained in the following (IV.b)

### ***Méthodologie de conception d'un modèle neuronal***

Compte-tenu des éléments théoriques et illustrations présentés précédemment, la méthodologie de conception d'un modèle neuronal doit permettre de proposer un modèle de complexité suffisante pour que la fonction souhaitée puisse être approchée, mais également de complexité minimale afin d'éviter le sur-ajustement. La recherche est encore active à ce sujet. Il est pour cela nécessaire de diviser la base de données en plusieurs sous-ensembles : (i) l'ensemble d'apprentissage qui sert à calculer les paramètres du modèle et à dimensionner le modèle pour obtenir la complexité optimale, (ii) l'ensemble d'arrêt qui sert à arrêter l'apprentissage avant que le réseau ne se spécialise à outrance sur le bruit contenu dans les données, et (iii) l'ensemble de test, indépendant des deux précédents qui sert à valider le modèle ainsi obtenu. Plus d'explications sur les méthodes de sélection de la complexité peuvent être trouvées dans (Dreyfus, 2008) et de manière plus précise celle adoptée dans ces études dans (Kong-A-Siou, 2011a).

### ***Le paradigme systémique***

« Tous les modèles sont faux ; certains sont utiles. » (G. E. Box, 1979)

Dès 1975 nous proposons une approche systémique de modélisation hydrodynamique du karst (Mangin, 1975). Celle-ci était fondée sur les mêmes hypothèses que l'apprentissage statistique : les signaux d'entrée et de sortie du système recèlent suffisamment d'informations pour réaliser un modèle efficace sans la connaissance détaillée, dans le temps ou dans l'espace, des processus élémentaires. Sa modélisation conceptuelle, fondée sur un enchaînement de blocs en cascade effectuant des opérations physiquement interprétables, représentée de manière simplifiée, nous a inspiré l'idée des boîtes transparentes, présentées au chapitre V., dès 1993. Après toutes ces années et maintenant mieux armés, tant au niveau outils que méthodologie, nous pensons pouvoir reprendre ce travail pour arriver à mieux connaître le karst.

### **Modèles hydrologiques par réseaux de neurones**

Considérons par exemple l'équation différentielle de remplissage d'un réservoir par un débit  $x(t)$  et sa vidange par un autre débit  $y(t)$  proportionnel à la hauteur d'eau dans le réservoir. Ce modèle est schématiquement celui qui est pris en compte pour représenter le fonctionnement d'un bassin versant par l'approche dite des *modèles conceptuels à réservoir*. On peut montrer aisément que l'équation différentielle liant les deux variables s'écrit :

$$\frac{S}{a} \frac{dy(t)}{dt} + y(t) = x(t)$$

Où  $S$  est la section constante du réservoir et  $a$  le coefficient de proportionnalité liant le débit sortant à la hauteur dans le réservoir ( $y(t)=ah(t)$ ).

Une fois discrétisée (le temps discret est noté  $k$ ), l'équation aux différences de ce processus s'écrit sous la forme :

$$y(k) = \frac{S}{a\Delta t + S} y(k-1) + \frac{a\Delta t}{a\Delta t + S} x(k)$$

où  $\Delta t$  est l'intervalle de temps séparant deux échantillons.

Ce qu'il est intéressant de noter est que le modèle de type réservoir est le modèle *postulé* du modèle physique de vidange d'un réservoir. Ce modèle *postulé* est récurrent, c'est un *filtre récursif non linéaire* : l'estimation de la sortie future  $y(k+1)$  dépend au moins d'une sortie précédente  $y(k)$ . On pourra remarquer que l'équation aux différences précédente peut être implémentée par un neurone unique ayant comme variable exogène (ou extérieure)  $x(k)$  et comme variable de bouclage  $y(k-1)$ .

Un « réseau » de un neurone unique n'est donc rien d'autre qu'un réservoir implémentant la loi de Maillet.

### **Modèles de prédicteur optimal**

O. Nerrand (Nerrand *et al*, 1993) ont présenté comment la connaissance que l'on a des perturbations et bruits opérant sur le modèle physique *postulé* récurrent d'un processus peut être prise en compte pour synthétiser un prédicteur optimal. Considérons un système physique représenté par un modèle de type entrée-sortie, dynamique (ou récurrent, c'est à dire avec un bouclage de la sortie vers l'entrée). Le modèle *postulé* réalise la fonction :

$$y(k+1) = \varphi(y(k), \dots, y(k-r+1), u(k), \dots, u(k-w+1))$$

Où  $\varphi$  est une fonction qui représente le fonctionnement du système physique étudié. Le modèle *postulé* reçoit en entrée les variables exogènes à l'instant  $k$  (vecteur  $\mathbf{u}(k)$ ) et la sortie  $y(k)$  ; sa



sortie est  $y(k+1)$ .  $q^{-1}$  est l'opérateur retard.  $r$  et  $w$  sont des entiers positifs qui correspondent à un historique sur les données présentées au modèle.

Ce modèle physique postulé peut être représenté schématiquement tel qu'en Figure 9.




Figure 9 : Modèle postulé récurrent.

Postulated recurrent model

**(i) Hypothèse bruit de sortie**

Dans l'hypothèse « bruit de sortie » (Figure 10), le modèle postulé peut être soumis à des perturbations additives sur sa sortie  $y^s(k+1)$ , correspondant par exemple à un bruit de mesure ( $\mathbf{b}(k+1)$ ). Ainsi, comme la sortie mesurée sur le processus  $y^p(k+1)$  est entachée d'erreur, on évite de l'utiliser dans l'estimation des sorties futures, on utilise donc en entrée la sortie estimée par le modèle neuronal lui-même : le modèle est récurrent (ou bouclé) ; il s'écrit ainsi :

$$y(k+1) = g_m(y(k), \dots, y(k-r+1), u(k), \dots, u(k-w+1), \theta)$$

où  $g_m$  est la fonction réalisée par le réseau de neurones,  $\mathbf{y}(k)$  la sortie du réseau,  $\mathbf{u}(k)$  le vecteur des variables exogènes,  $r$  et  $w$  sont des entiers positifs,  $\theta$  est le vecteur des paramètres.




Figure 10 : Modèle physique postulé (10.a) et le prédicteur associé (10.b) à l'hypothèse bruit de sortie. Postulated physical model (10.a) and the predictor associated to the « output error hypothesis » (10.b).

Le prédicteur ainsi obtenu peut effectuer des prévisions pour un horizon indéfini à condition de disposer des prévisions de ses variables exogènes (pluies). Ceci n'est pas toujours possible pour les phénomènes naturels, néanmoins, par exemple, ce prédicteur pourrait être utilisé pour estimer l'impact du changement climatique sur les ressources en eau. Les entrées exogènes seraient alors les précipitations issues de modèles climatiques correspondant à différents scénarios et les sorties seraient des débits ou des niveaux de nappe estimés. Ce modèle sera appelé dans la suite : modèle récurrent.

**(ii) Hypothèse bruit d'état**


Dans l'hypothèse *bruit d'état* (Figure 11), le modèle postulé est soumis à des perturbations additives sur son état ( $\mathbf{b}(k+1)$ ), par exemple le modèle a été mal calibré ou le bassin versant a

subi des modifications qui ont fait évoluer son comportement (pressions anthropiques, changement climatique, déforestation, etc ...).

Comme son état est bruité il est alors plus intéressant d'appliquer en entrée correspondant au bouclage les variables observées du processus. Le prédicteur associé s'écrit donc :

$$y^s(k+1) = g_m(y^p(k), \dots, y^p(k-r+1), u(k), \dots, u(k-w+1), \theta)$$

Où  $g_m$  est la fonction réalisée par le réseau de neurones,  $y(k+1)$  la sortie du réseau,  $u(k)$  le vecteur des variables exogènes,  $r$  et  $w$  sont des entiers positifs,  $\theta$  est le vecteur des paramètres.



**Figure 11 : Modèle physique postulé (11.a) et le prédicteur associé (11.b) à l'hypothèse bruit d'état. Postulated physical model (11.a) and the predictor associated to the « state error hypothesis » (11.b).**

Même si ce prédicteur a vocation à simuler un système dynamique tel qu'un bassin versant, on peut remarquer qu'il n'est pas récurrent. Comme il est alimenté par les sorties mesurées du processus, ce prédicteur est appelé non-récurrent, par opposition au prédicteur récurrent présenté précédemment.

En pratique, ce prédicteur non récurrent est celui qui délivre les meilleures simulations ou prévisions des hauteurs ou débits comme nous le présenterons en section IV de cet article. Ce dernier point pourrait laisser à penser que les principales erreurs interviennent donc sur l'estimation de l'état du processus. On note également que la prévision réalisée à l'instant  $k$  nécessite les mesures de la sortie aux instants précédents ( $k-1, \dots, k-r+1$ ), on dit alors que la prévision est faite à « 1 coup » ; ce modèle ne peut donc être utilisé pour des prévisions ou simulations sur un plus long horizon puisque la mesure de sa variable de sortie est nécessaire.

### **Modélisation pluie-débits**

#### **Comparaison des modèles récurrents et non-récurrent**

La méthodologie esquissée au paragraphe III.c. a été appliquée à la modélisation de la relation pluie-débit du bassin du Baget. Les entrées de pluies sont les précipitations journalières à la station de Balagué et les débits sont ceux mesurés à l'aval du bassin. Sont représentées en **Figure** les évolutions des pluies et du débit durant l'année 1999 qui est l'année de test de notre étude ; on y note un étiage prononcé durant l'été et le début de l'automne et une période de hautes eaux durant l'hiver et le printemps. De manière contrastée avec le bassin karstique du Lez, on peut noter que la pluie est persistante durant toute l'année ce qui n'empêche pas, du fait de l'évapotranspiration, que le débit marque un étiage très net.

La base de données utilisée possède les mesures journalières de débit en aval de l'exutoire du 31 août 1973 au 30 décembre 1999, sans lacune, et les données pluviométriques journalières mesurées à la station de Balagué pour la même période.


Grâce à cette base de données, la modélisation de la relation pluie-débit a pu être réalisée ; elle est évaluée sur une année complète (année de test) : l'année 1999. Nous pouvons reproduire les hydrogrammes simulés avec les deux prédicteurs précédemment présentés : récurrent et non récurrent. La table 2 reporte les critères de Nash obtenus dans les deux configurations. Il est à noter qu'une étude doit être réalisée à chaque fois pour estimer les largeurs des fenêtres temporelles optimales, ainsi que le nombre de bouclages et le nombre optimum de neurones cachés ; dans ce cas ces valeurs ne varient pas selon les modèles choisis.

|                 | Récurrent   | Non récurrent  |
|-----------------|---|--|
| Architecture    | 17 jours d'historique de pluies<br>10 neurones dans la première couche cachée<br>5 neurones dans la seconde couche cachée<br>bouclage avec les débits estimés pour les 3 jours précédents | 17 jours d'historique de pluies<br>10 neurones dans la première couche cachée<br>5 neurones dans la seconde couche cachée<br>2 jours de débits précédents observés |
| Critère de Nash | 0,65  | 0,89   |

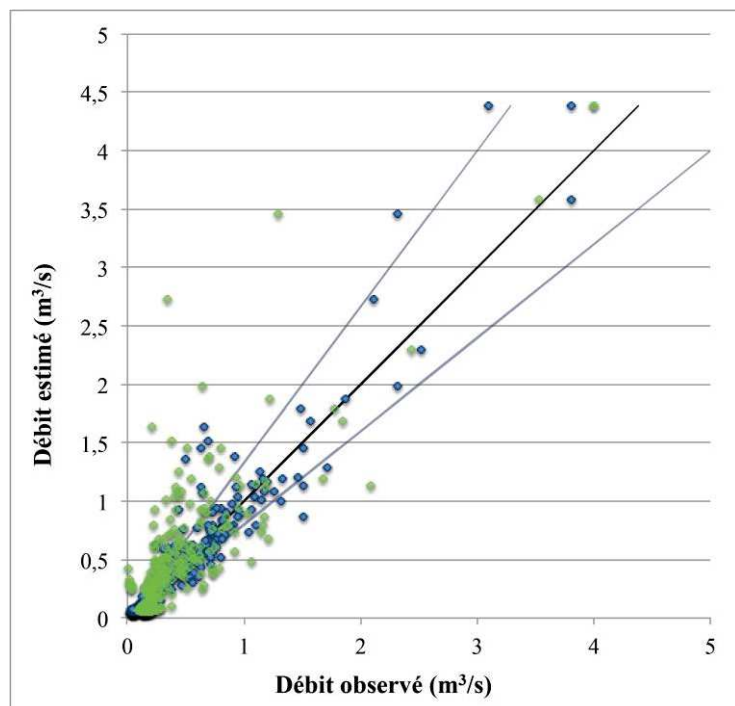
**Table 2 : Présentation synthétiques des meilleures architectures définies**

Comme présenté précédemment, il apparaît clairement que la simulation est meilleure lorsque le modèle non-récurrent est utilisé. On peut en effet comprendre qu'il est plus facile de simuler le débit du lendemain à partir des pluies et du débit des jours précédents, qu'à partir de la seule information de pluie.

Les trois hydrogrammes correspondant au débit observé et aux estimations des modèles récurrent et non-récurrent sont présentés en Figure 12. On pourra noter que les hydrogrammes simulés sont bons sauf celui du modèle récurrent pour une crue de début d'année. En l'absence des mesures de température, on ne peut rigoureusement affirmer que cette crue est due à la fonte de neige. Dans cette dernière hypothèse il est normal que le réseau ne puisse anticiper ce phénomène, n'ayant pas les informations nécessaires en entrée.



(a) Hydrogrammes : trait noir : débit observé, trait pointillé bleu débit estimé par le modèle non-récurrent ; trait tireté vert : débit simulé par le modèle récurrent.



(b) Diagramme de dispersion. Points bleus : débits estimés par le modèle non-récurrent ; points vert : débits simulés par le modèle récurrent. La première bissectrice est figurée par une droite noire, ses valeurs encadrées à + ou - 25% sont figurées par des traits continus bleus.

**Figure 12 : Simulation du débit du Baget par réseaux de neurones : comparaison des simulations issues du modèle récurrent et du modèle non-récurrent. *Baget* discharge simulation with neural networks : comparison between recurrent and non-recurrent model.**

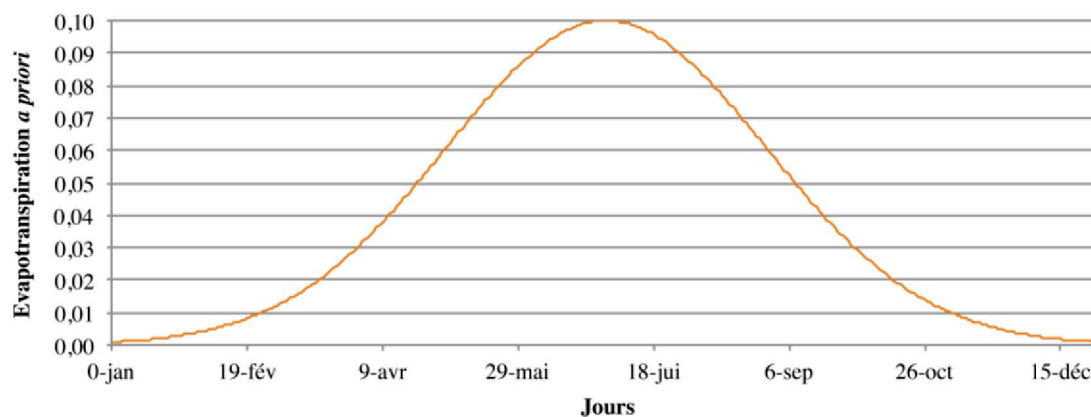
Il apparaît donc que la modélisation par réseaux de neurones est fiable pour effectuer la prévision à « un coup » (modèle non-récurrent), est qu'elle est moins satisfaisante pour la prévision à plus longue échéance (modèle récurrent). Néanmoins l'on peut comprendre que le modèle récurrent qui calcule le débit à partir des seules informations de pluie et de débit ne peut anticiper sur les différences de comportement de l'aquifère en l'absence d'information sur l'évapotranspiration potentielle, ou en l'absence d'information comme la température. En

revanche, le modèle non-récurrent ne souffre pas de la même limitation car les mesures du débit observé qu'il reçoit en entrée peuvent le renseigner sur l'état du bassin. Schématiquement : en été lorsque le bassin est sec, la pluie n'entraîne pas d'augmentation de débit, c'est une information que le modèle non-récurrent reçoit en entrée ; alors qu'en automne et au printemps les pluies entraînent une augmentation de débit en entrée du modèle.

En conséquence si l'on veut utiliser le modèle récurrent à des fins de prévision à moyen ou long terme en disposant de prévision des précipitations il convient d'appliquer une autre entrée qui puisse alimenter le modèle avec une information relative à l'évapotranspiration.

### **Prise en compte de l'évapotranspiration**

Afin de prendre en compte l'évapotranspiration, l'approche classique consisterait à utiliser une formule d'estimation de l'évapotranspiration (la formule de Turc par exemple) et à laisser le réseau apprendre. En l'absence de mesures de températures, il est néanmoins possible de présenter au réseau un signal d'entrée qui n'est pas construit en fonction de la température mesurée, mais d'une variation *a priori* de l'évapotranspiration potentielle. Ainsi, nous pouvons construire une fonction en cloche qui possède sa valeur maximale en été et minimale en hiver : à charge au réseau de neurones de la transformer pour intégrer l'évapotranspiration à son estimation (Figure 13).



**Figure 13 : Évapotranspiration potentielle *a priori*.**

#### ***A priori* potential evapotranspiration**

De nouvelles simulations sont alors réalisées en intégrant cette évapotranspiration *a priori* comme entrée au modèle sur une fenêtre temporelle de même largeur que celle des précipitations. L'estimation du modèle récurrent comportant en entrées les précipitations, l'évapotranspiration *a priori* et les débits estimés précédents, donne un hydrogramme simulé dont le critère de Nash vaut maintenant 0,72 par rapport au débit observé. La simulation a donc bien été améliorée.

En l'absence de données climatiques complémentaires il est difficile d'aller au-delà de ces résultats mais il est intéressant de les comparer à ce qu'aurait obtenu un système purement linéaire. Nous avons pour cela réalisé le calcul d'un filtre linéaire identifiant la relation pluie-débit, comportant l'entrée évapotranspiration *a priori*. Comme attendu, les résultats sont moins bons qu'avec le réseau de neurones, et le critère de Nash obtenu vaut 0,64. L'hydrogramme obtenu est le suivant (Figure 14), il est visiblement moins bon que celui relatif à l'estimation réalisée par le réseau récurrent, en particulier pour les pics de l'automne et pour la période

d'étiage où le filtre linéaire «invente» des crues lors des épisodes pluvieux : il n'arrive pas à traiter correctement le signal fictif d'évapotranspiration *a priori*.

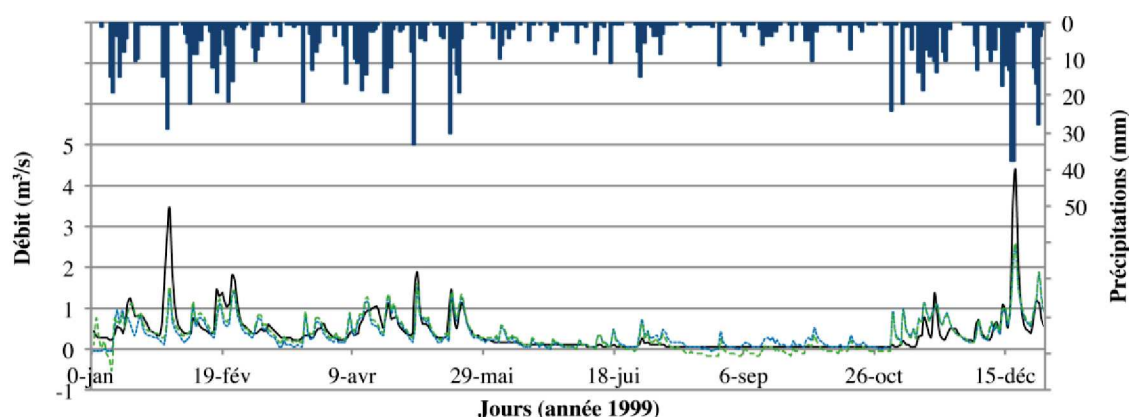


Figure 14 : Estimation de débit réalisée par un filtre linéaire. En noir la sortie mesurée, en vert la sortie du modèle linéaire, en bleu la sortie du modèle neuronal.

Estimated discharge by linear filtering. In black, the measured discharge, green the linear filter, blue neural model output.

En réalisant un focus sur la période d'étiage, présenté sur la Figure 15, on peut noter un comportement contradictoire du filtre linéaire : il n'arrive pas à gommer tout à fait l'effet des pluies qui ne ressortent pas à la rivière (pics «inventés»), et d'un autre côté, il atténue tellement le débit d'étiage que ce dernier devient parfois négatif. Ces observations sont compatibles avec le fait que le filtre linéaire ne peut exploiter les combinaisons des entrées « évapotranspiration » et « pluies » qu'en leur faisant des modifications d'amplitudes ; il ne peut pas les transformer plus fondamentalement.

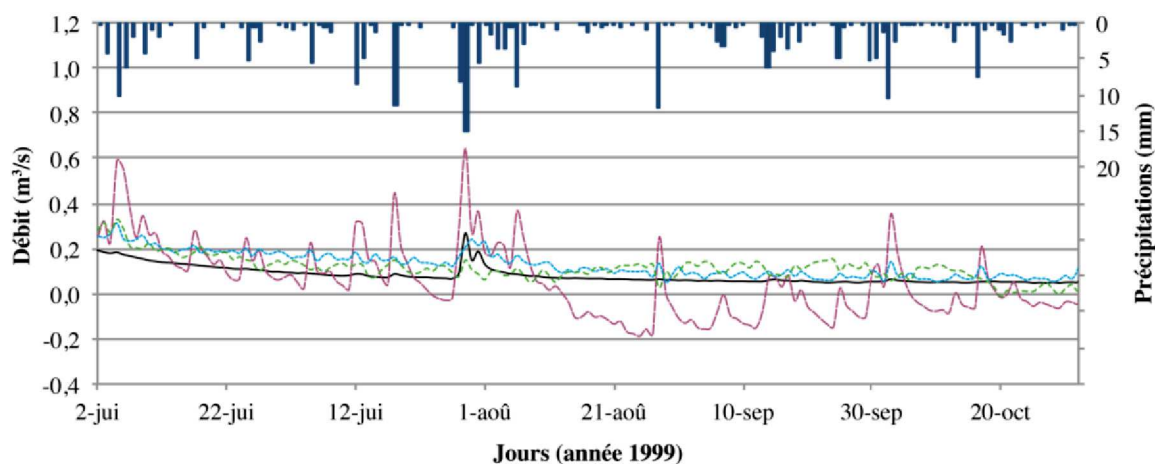


Figure 15 : Estimation des débits en étiage. Trait noir : débit observé, trait pointillé bleu débit estimé par le modèle non-récurrent ; trait tireté vert : débit simulé par le modèle récurrent ; tireté rouge : débit estimé par le filtre linéaire.

Estimation of discharge in low flow period. Black line: observed discharge, blue dashed line: feed-forward model ; green dashed line : recurrent model ; red dashed line : linear filtering.

### Vers une meilleure connaissance des systèmes étudiés

Dans les paragraphes précédents nous avons pu présenter comment un modèle à réseaux de neurones pouvait réaliser une fonction *a priori* inconnue et complexe, comme celle de la relation pluie-débit d'un aquifère karstique, pourvu que des bases de données soient disponibles et que l'écueil du sur-apprentissage soit bien appréhendé. Les applications en prévision ou simulation

peuvent alors apporter des bénéfices aux enjeux sociétaux tels que la prévision des crues ou des étiages. Néanmoins compte tenu des bons résultats obtenus, nous avons émis l'hypothèse que le modèle neuronal réalisait une fonction proche de celle effectuée par le modèle physique, tout au moins sur un certain domaine de validité. Ainsi, autant pour valider cette hypothèse que pour mieux connaître le comportement des aquifères karstiques, nous avons cherché à extraire des informations du modèle neuronal réalisé. Deux méthodes ont été proposées qui sont présentées ci-dessous : la méthode KnoX et les boîtes transparentes.

### **Boîtes transparentes**

L'approche des boîtes transparentes a été utilisée dans l'exemple suivant pour estimer le signal d'évapotranspiration. Cette information est en effet cruciale pour les modèles hydrologiques qui opèrent souvent sur les pluies efficaces<sup>2</sup>. Si plusieurs modèles d'évapotranspiration existent, il a également été montré par L. Oudin que la précision du modèle d'évapotranspiration n'a que peu d'importance et qu'un modèle assez rustique ne prenant en compte que l'évolution de la température pour estimer l'évapotranspiration potentielle peut suffire (Oudin *et al*, 2004).

Le modèle hypothèse de processus physique que nous avons utilisé pour simuler l'évapotranspiration est le suivant : un premier processus effectue la conversion pluie-débit, tandis que le processus d'évapotranspiration prélève de l'eau à la conversion pluie-débit (Figure 16). Les variables d'entrées de la modélisation par boîtes transparentes sont bien entendu prépondérantes puisqu'elles conditionnent la représentation physique. Ainsi, les précipitations alimentent la relation pluie-débit tandis qu'une courbe en gaussienne maximale au 30 juin (sous nos latitudes, Figure 13) représente les variations schématiques des variables climatiques prépondérantes sur l'évapotranspiration (température, radiations solaires).

Appliquées aux données du karst du Baget, présenté en section II.a, et après plusieurs raffinements successifs, nous avons obtenu pour l'évapotranspiration observée dans le réseau de neurones (Figure 16) une courbe différente de la gaussienne appliquée en variable d'entrée. On peut y noter en particulier une translation systématique du maximum au mois de septembre (Johannet *et al*, 2008-a). L'interprétation de ce maximum n'est pas très aisée à faire. En effet, la sortie du neurone "évapotranspiration" est le résultat d'un calcul effectué sur des variables d'entrée qui ne dépendent pas de la pluie, on penserait donc observer l'évapotranspiration potentielle. Or, il faut se souvenir que le calcul des paramètres a été effectué à partir d'une erreur calculée en sortie, qui dépend donc des précipitations observées, et ferait alors intervenir l'évapotranspiration réelle. Ce que l'on obtient à la sortie du neurone "évapotranspiration" est donc une grandeur différente des deux précédentes, qui transcrit l'eau que la végétation consomme, que cette eau vienne d'être précipitée, ou qu'elle se situe dans des réserves plus profondes. Il s'agirait d'un *déficit en écoulement* moyen causé par la végétation et l'évaporation. Cette notion serait intéressante à discuter car elle a plus de sens, hydrologiquement parlant, que celle d'évapotranspiration, qui est avant tout une notion introduite en agronomie.

Après avoir validé plus amplement cette analyse sur d'autres bassins versants, nous pensons que ce type d'information pourrait être utilisé pour évaluer l'impact d'un changement de pratiques agricoles ou d'un changement d'occupation des sols sur les réserves en eau.

---

<sup>2</sup> Les pluies efficaces sont les pluies auxquelles on a retiré l'évapotranspiration réelle (ETR) ; cette dernière dépend de l'évapotranspiration potentielle (ETP) et de l'eau effectivement disponible pour l'évaporation et la consommation par la végétation (réserve du sol, précipitations).

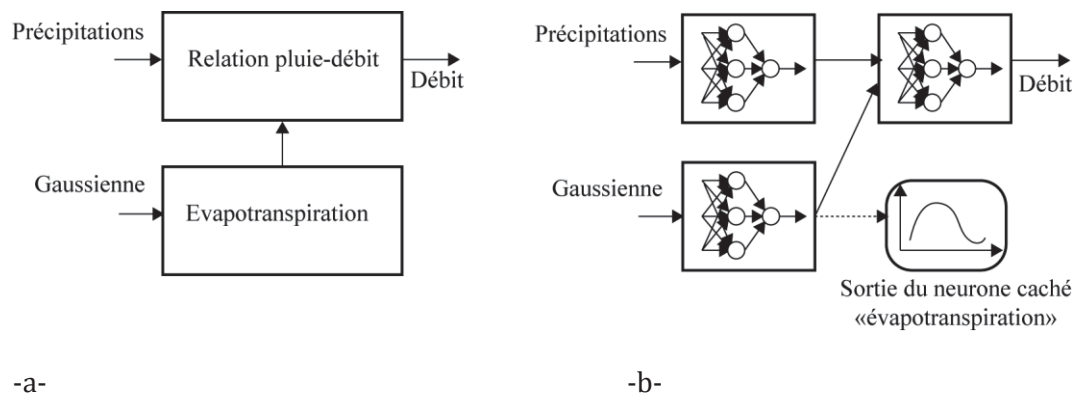


Figure 16 : Boîte transparente pour mettre en évidence le déficit d'écoulement

16-a. Modèle postulé (hypothèse physique). 16-b. Déclinaison de l'hypothèse physique en utilisant un réseau de type perceptron multicouche pour identifier chacune des fonctions physiques inconnues.

Transparent box devoted to water losses visualization

### Méthodologie KnoX

La méthodologie KnoX, comme Knowledge eXtraction a été appliquée à l'hydrosystème du Lez. Afin de mieux connaître les écoulements souterrains de cet hydrosystème, un découpage du bassin d'alimentation supposé en quatre zones géologiques estimées homogènes a été proposé par Line Kong A Siou lors de son travail de thèse [Kong-A-Siou, 2011], ce découpage est présenté au paragraphe III-b. Relativement à chacune des zones baptisées Nord-Est, Nord-Ouest, Sud-Est et Sud-Ouest, nous avons défini autant de chroniques pour des pluviomètres dits « virtuels » qui enregistreraient les précipitations tombant sur ces zones (Figure 17). Ces chroniques ont été définies à partir de six pluviomètres présents dans le bassin ou à proximité de celui-ci en utilisant une méthode géométrique de pavage du plan (polygones de Thiessen) afin de définir la "contribution" de chacun de ces pluviomètres à chaque zone.

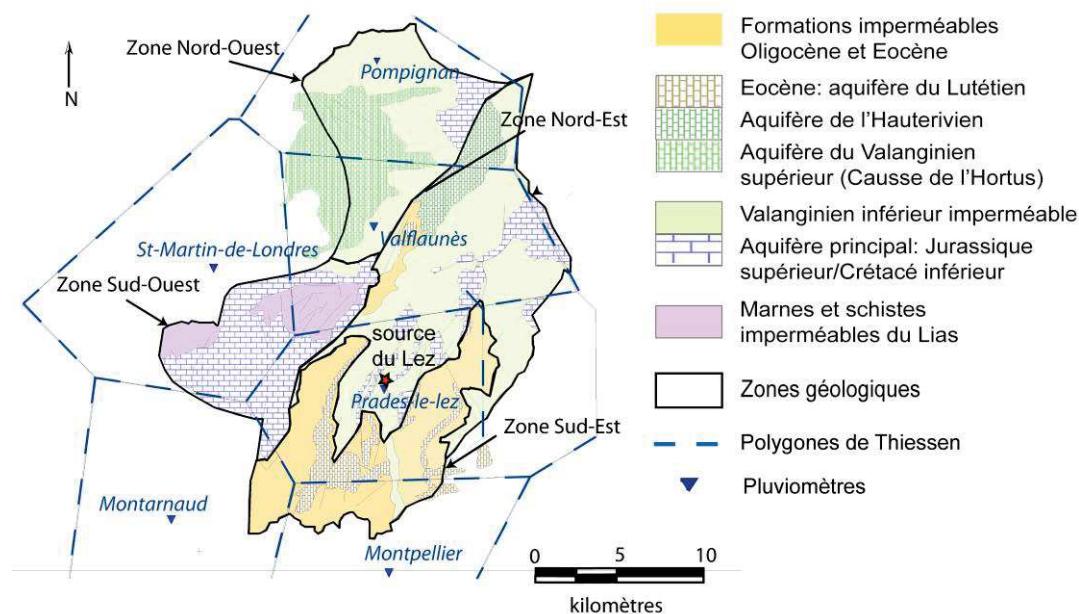
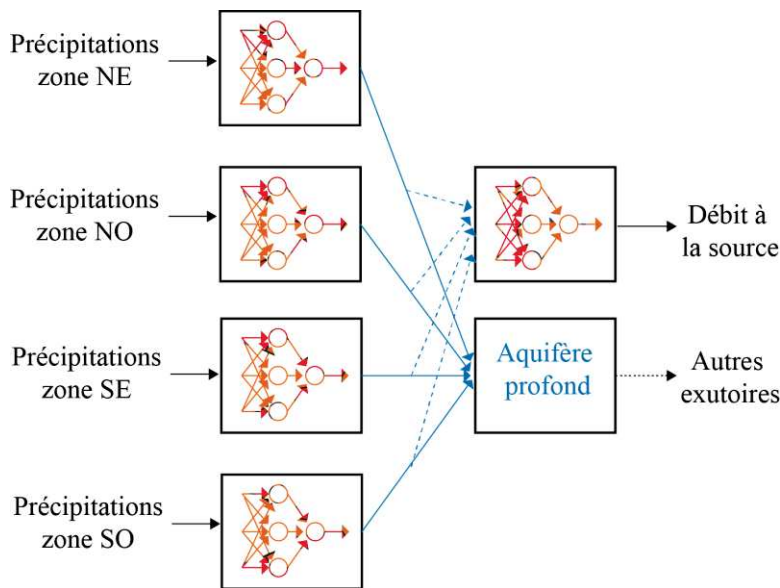


Figure 17 : Zones géologiques, pluviomètres et polygones de Thiessen sur le bassin hydrogéologique du Lez  
Geological zonation, rain gauges and Thiessen polygons on the Lez Basin.



Nous avons émis l'hypothèse selon laquelle l'eau tombant sur chacune de ces zones : *i*) alimente l'aquifère profond, *ii*) ressort à la source du Lez, *iii*) sort à un autre exutoire. En contraignant l'architecture du réseau de neurones par ces hypothèses, un modèle hypothèse a été proposé tel que représenté sur la Figure 18. Sa mise en œuvre a été simplifiée par souci de parcimonie et les réseaux de type identificateur universel correspondant à l'infiltration de chacune des zones ont été remplacés par un seul neurone linéaire. De l'information a été extraite de chacun de ces sous-réseaux en utilisant la méthode de sélection de variables proposée par (Yacoub et Benani, 2001) qui permet de quantifier l'importance de chacune des variables. Ainsi, nous avons pu extraire, pour chacune des zones, d'une part le volume relatif de l'eau sortant à la source provenant de cette zone et d'autre part le temps de transfert de l'énergie<sup>3</sup> issue des précipitations tombant sur la zone (Kong-A-Siou *et al.* 2013).



**Figure 18 : Modèle postulé pour la simulation hydrodynamique de l'aquifère du Lez.**

La validation de la méthode d'extraction des temps de transfert et des volumes relatifs a été effectuée en construisant un modèle hydrologique avec le logiciel HEC-HMS (HEC-HMS) qui représente le type de fonctionnement que nous cherchons à identifier : quatre sous-bassins dont le débit est partiellement collecté dans un drain qui sort à la source du Lez, le reste de l'eau étant transmis à l'aquifère pour émerger à d'autres exutoires. Pour chaque sous-bassin, le pourcentage d'eau exurgeant à la source ainsi que le temps de transfert de l'énergie (la constante de temps) ont été imposés et devraient donc être retrouvés dans le modèle. Les résultats obtenus concernant les contributions sont synthétisés dans la Table 3. Il s'agit d'une moyenne sur quatre modèles du bassin virtuel, différents par leur dynamique.

| Contribution au débit                   | Z <sub>1</sub> | Z <sub>2</sub> | Z <sub>3</sub> | Z <sub>4</sub> |
|---|----------------|----------------|----------------|----------------|
| Imposée dans le bassin-versant virtuel  | 33,9%          | 37%            | 8,4%           | 19,2%          |
| Extrait du modèle neuronal (moyenne sur | 35,3%          | 37,3%          | 8,8%           | 18,5%          |

<sup>3</sup> Le retard estimé correspond au temps que met l'onde de crue à traverser le karst ; il ne s'agit donc pas de transfert de matière mais de transfert d'énergie.

quatre bassins virtuels différents)

|            |       |       |       |       |
|------------|-------|-------|-------|-------|
| Ecart type | 2,86% | 3,49% | 3,49% | 1,66% |
|------------|-------|-------|-------|-------|

**Table 3 : Validation de la méthode KnoX à partir d'un aquifère virtuel.**

Appliquée dans un second temps au bassin d'alimentation du Lez, la méthode fournit les pourcentages de contribution de chaque zone au débit observé à la source (Table 4). Les contributions sont estimées à partir des paramètres médians correspondant à 50 réseaux obtenus à partir d'initialisations différentes des paramètres du réseau de neurones afin de s'affranchir d'un cas particulier.

| Contribution au débit   | Zone NO | Zone NE | Zone SO | Zone SE |
|-------------------------|---------|---------|---------|---------|
| Boîte transparente      | 29%     | 52%     | 13%     | 6%      |
| Temps de réponse (jour) | 1 à 3   | 1       | 1       | <1      |

**Table 4 : Contribution des zones estimée par la boîte transparente**

Les contributions des zones au débit de la source appellent plusieurs commentaires. A la première lecture, on est surpris de la faible importance de la zone Sud-Ouest qui est pourtant une zone de recharge importante de l'aquifère ; cependant cette faible contribution est explicable car la source du Lirou draine cette zone en hautes eaux (on ne peut actuellement calculer cette contribution car la source du Lirou n'est jaugée que depuis peu de temps). Les contributions des zones Nord-Ouest et Nord-Est correspondent à ce que l'on peut attendre : on sait que la zone Nord-Est contribue directement à l'alimentation de la source puisque des mesures de hauteur d'eau dans la nappe montrent qu'elle est directement influencée par les pompages effectués dans le drain du Lez. En effet, des piézomètres implantés sur le site du Terrieu situé à quelques kilomètres de la source voient le niveau de la nappe baisser très rapidement lorsque le pompage dans le Lez est effectif (Jazayeri Noushabadi, 2009). Par ailleurs la contribution de la zone Nord-Ouest doit arriver à la source à la faveur de la faille de Corconne, accident tectonique majeur qui sépare le bassin d'alimentation en deux et draine l'eau vers le sud. Enfin, la très faible importance de la contribution de la zone Sud-Est paraît indiquer que cette zone est peu ou pas comprise dans le bassin d'alimentation de la source. Ceci étant d'autant plus justifié que la zone Sud-Est est constituée de terrains imperméables (avec quelques aquifères perchés) sur lesquels l'eau ruisselle pour atteindre le fleuve du Lez à l'aval de la source. Quelques apports marginaux à l'aquifère pourraient cependant se produire à la faveur de failles.

Pour valider cette dernière hypothèse, une autre manipulation a été réalisée en ajoutant à l'aquifère une cinquième zone fictive d'alimentation, définie par un pluviomètre "recevant" des précipitations d'intensités aléatoires lorsque des pluies sont enregistrées sur au moins un des quatre pluviomètres virtuels de la zone, et nulles autrement. Extraite de la boîte transparente, la contribution de cette zone est apparue quasi nulle. Cette dernière expérience permet donc d'affirmer que lorsque les variables d'une zone n'affectent pas le débit, la zone est identifiée par la méthode KnoX comme peu contributive. Ce dernier point renforce la proposition consistant à redéfinir le bassin d'alimentation en excluant une grande partie de la zone SE.

## **Conclusion**

Cet article a présenté comment les réseaux de neurones, méthode de modélisation issue de l'intelligence artificielle, pouvaient aider à mieux appréhender le fonctionnement hydrodynamique des aquifères karstiques grâce à leur capacité à représenter de manière empirique des fonctions *a priori* inconnues. Grâce à cette propriété les réseaux de neurones sont donc tout particulièrement adaptés à représenter les fonctions réalisées par les hydrosystèmes complexes ou hétérogènes pour lesquels il n'existe pas de modèle physique, par manque de connaissance. Après une présentation simplifiée du fonctionnement de ces systèmes appartenant à l'apprentissage statistique, leur limite - le dilemme biais-variance - a été présentée et illustrée. Partant d'un modèle de type boîte noire dans lequel aucune information sur les processus n'était apportée au modèle, il a été montré qu'il était possible de réaliser efficacement des fonctions telles que la simulation des débits d'une source karstique. Autant par souci de validation des modèles ainsi obtenus que pour améliorer leurs performances, il a ensuite été proposé de contraindre l'architecture du modèle sous la forme de schéma-bloc afin de pouvoir calculer, par le réseau de neurones, chacun des blocs de ce modèle hypothèse. Inspirées de ce principe, deux types d'approches ont été présentées : l'une appelée « boîte transparente » a permis d'extraire du modèle une information sur le « déficit d'écoulement hydraulique » ; l'autre baptisée KnoX a permis de mieux déterminer l'origine des eaux souterraines et de mieux quantifier les temps de transferts au sein de l'aquifère. Ainsi, les réseaux de neurones, grâce à une méthodologie de conception rigoureuse, loin de leur réputation d'objets mathématiques invérifiables, ont pu permettre d'améliorer la connaissance que nous avons de deux hydrosystèmes karstiques : le Lez (Hérault) et le Baget (Ariège). Ces méthodes étant génériques et transposables à d'autres aquifères dès que l'on dispose d'une base de données suffisante, nous pensons qu'un vaste champ d'applications et d'échanges fructueux entre les communautés des modélisateurs et des karstologues de terrain peut être exploré par de telles approches.

## **Remerciements**

Pour la fourniture des données sur le bassin du Lez, nous remercions Météo France pour les pluies et la DIREN de Montpellier pour les hauteurs d'eau et débits à la source du Lez. Pour les nombreuses et enrichissantes discussions que nous avons pu avoir, ainsi que pour leur disponibilité, nous remercions Messieurs Henri Paloc, Pierre Bérard et Pierre Roussel-Ragot.

## **Références**

Alt, F.L. Archaeology of computers: Reminiscences, 1945—1947. In Communications of the ACM, special issue: Twenty-fifth anniversary of the Association for Computing Machinery, vol. 15 7, pp. 693-694 (1972).

Bérard, P. (1983). *Alimentation en eau de la ville de Montpellier. Captage de la source du Lez étude des relations entre la source et son réservoir aquifère. Rapport n°2: Détermination des unités hydrogéologiques*. BRGM Montpellier.

Barron, A.R. (1993). *Universal approximation bounds for superpositions of a sigmoidal function*. IEE Trans Inf Theory 39 (3):930–945.

Borrell-Estupina, V., Ladouche, B., Malaterre, P.-O., Ricci, S., Caballero, Y., Coustau, M., Dorfliger, N., Fleury, P., Jay-Allemand, M., Maréchal, J.-C., Thual O. (2014). *Forecasting and mitigation of flooding in a Mediterranean karstic watershed*. Hydrology in a Changing World: Environmental and Human

Dimensions Proceedings of FRIEND-Water 2014, Hanoi, Vietnam, February 2014 (IAHS Publ. 36x, 2014).

Bender, E. (1996). *Mathematical Methods in Artificial Intelligence*. IEEE Computer Society Press, 636 p.

Box, G.E.P. (1979). *Robustness in the strategy of scientific model building*. In *Robustness in Statistics*, R.L. Launer, G.N. Wilkinson, ed. (1979).

Dreyfus, G., Samuelides, M., Martinez, J.-M., Gordon, M.-B., Badran, F., Thiria, S., Hérault, L. (2008). *Apprentissage statistique*. Eyrolles 450 p.

Fleury P., Charlier J.-B., Borrell V., Coustau M. (2011). Appui au SCHAPI 2011 - Module 1 - Mise en place d'un indicateur d'aide à la décision pour la prévision de crue en milieu karstique : les bassins versants du Lez et de la Tardoire. Rapport BRGM RP-60380-FR.

Fleury, P., Ladouche, B., Conroux, Y., Jourde, H., and Dörfliger N. (2008), *Modelling the hydrologic functions of a karst aquifer under active water management - The Lez spring*, *Journal of Hydrology*, 365 (3-4), 235-243.

Gallinari, P., Cibas T. (1999). *Practical complexity control in multilayer perceptrons*. In *Signal Processing 74*: 29-46

Geman, S., Bienenstock, E., Doursat, R. (1992) *Neural networks and the bias/variance dilemma*. *Neural Computation* 4(1): 1–58

Hornik, K., Stinchcombe, P., White, H. (1989). *Multilayer feed-forward neural networks are universal approximator*, *Neural Networks* 2: 359-366

Jazayeri Noushabadi, M. R. (2009). *Characterisation of relationships between fracture network and flow-path Network in fractured and karstic reservoirs. Numerical modeling and field investigation (Lez aquifer, Southern France)*. Thèse de l'Université Montpellier II

Johannet, A., Vayssade, B., Bertin, D. (2008a). *Neural Networks: From Black Box Towards Transparent Box. Application to Evapotranspiration Modeling*. In *International Journal of Computational Intelligence* 4 (3): 163-170

Johannet, A., Mangin, A., Vayssade, B. (2008b). *Modélisation d'un système karstique par réseaux de neurones. Simulation des débits du karst du Baget-France*. In *Cahiers de Géographie-collection EDYTEM 7* : 51-62

Johannet, A. (2010). *Artificial Neural Networks*. In *Environmental hydraulics 2: Mathematical Models*, J.M.Tanguy, ed.

Karam, Y. (1989). *Essai de modélisation des écoulements dans un aquifère karstique. Exemple de la source du Lez (Hérault, France)*. Thèse Université Montpellier II Sciences et Techniques du Languedoc.

Kong A Siou, L. (2011a) *Modélisation des crues de bassins karstiques par réseaux de neurones. Cas du bassin du Lez (France)*. Thèse université Montpellier II

Kong A Siou, L., Johannet, A., Borrell, V., Pistre, S. (2011b). *Complexity selection of a neural network model for karst flood forecasting: The case of the Lez Basin (southern France)*. *Journal of Hydrology* 403 (367-380)

- Kong A Siou, L., Johannet, A., Borrell Estupina, V., Pistre, S. (2012) *Optimization of the generalization capability for rainfall-runoff modeling by neural networks: The case of the Lez aquifer (southern France)*. Environmental Earth Sciences 65 (8) : 2365-2375
- Kong-A-Siou, L., Cros, K., Johannet, A., Borrell-Estupina, V., Pistre, S. (2013) *KnoX method, or Knowledge eXtraction from neural network model. Case study on the Lez aquifer (southern France)*. Journal of Hydrology 507 (19-32)
- Marjolet, G., Salado, J. (1976). *Contribution à l'étude de l'aquifère karstique de la source du Lez (Hérault)*. Thèse Université des Sciences et Techniques du Languedoc (Montpellier).
- Mangin, A. (1970). Le système karstique du Baget (Ariège). Annales de Spéléologie, 25, 3.
- Mangin, A. (1975). *Contribution à l'étude hydrodynamique des aquifères karstiques*. Thèse Université de Dijon. Laboratoire souterrain du Centre national de la recherche scientifique.
- Nash, J.E. Sutcliffe, J.V., (1970). *River flow forecasting through conceptual models part I – A discussion of principles*, Journal of hydrology 10(3), 282-290.
- Nerrand, O., Roussel-Ragot, P., Personnaz, L., Dreyfus, G., Marcos, S. (1993). *Neural networks and nonlinear adaptive filtering: Unifying concepts and new algorithms*. Neural Computation, 5(2) : 165-199.
- L. Oudin. (2004) *Recherche d'un modèle d'évaporation potentielle pertinent comme entrée d'un modèle pluie-débit global*. Thèse de doctorat, ENGREF, Paris, 290 p.
- Paloc H. (1979). *Alimentation en eau de la ville de Montpellier. Localisation d'un emplacement de captage dans le réseau souterrain de la source du Lez. Détermination de ses principales caractéristiques en préalable à l'exécution des travaux*, BRGM/79-SGN-654-LRO, BRGM, Montpellier.
- Press, W.H., Teukolsky, S.A., Vetterling, W. T., Flannery, B.P. (1992) *Numerical Recipes in C*, Cambridge University Press/
- Rouch R. (1982). *Le système karstique du Baget. La communauté des Harpacticides. Comparaison de la dérive des Harpacticides à l'entrée et à la sortie de l'aquifère*. Ann. Limnol., 18, 2, p. 133-150.
- Yacoub, M., Bennani, Y., (2001). *Une mesure de pertinence pour la sélection de variables dans les perceptrons multicouches*, In Revue d'Intelligence Artificielle, 15 : 393-410.

### 3.2.3. COMPLEMENTS A L'ARTICLE

#### 3.2.3.1. FORMALISATION MATHÉMATIQUE

Comme nous l'avons annoncé en préambule, certains concepts et méthodes relatifs à la modélisation hydrodynamique par réseaux de neurones vont être explicités de façon mathématique afin de mieux appréhender le fonctionnement des différents modèles. Nous verrons donc dans un premier temps les formules relatives à l'apprentissage et aux opérations effectuées par les neurones. La suite sera essentiellement consacrée aux architectures proposées, la dernière partie, avant la conclusion, concernera les notions de boîtes grises et de boîtes transparentes présentées comme des alternatives aux boîtes noires souvent critiquées.

##### 3.2.3.1.1. APPRENTISSAGE

L'apprentissage est la minimisation itérative de la fonction de coût par l'utilisation de la règle d'apprentissage de Levenberg-Marquardt.

La fonction de coût ( $J$ ) peut être exprimée de la façon suivante :

$$J = \sum_{k=1}^{k_{\max}} (q^k - s^k(\mathbf{w}))^2$$

Avec  $q^k$  le débit observé (que l'on cherche à représenter) au temps discret  $k$ ,  $s^k$  le débit simulé à l'instant  $k$ , et  $\mathbf{w}$  la matrice des paramètres du modèle.

##### 3.2.3.1.2. LE MODELE DU NEURONE

Le neurone ( $i$ ) effectue 2 opérations :

- le calcul de son potentiel ( $v_i^k$ ) par la somme pondérée de ses entrées.

$$v_i^k = \mathbf{u}^k \mathbf{w}_i$$

Avec  $\mathbf{u}^k$  le vecteur de variables d'entrées et  $\mathbf{w}_i$  le vecteur de paramètres associés aux entrées du neurone ( $i$ ).

- le calcul de sa sortie ( $s_i^k$ ) par l'application au potentiel ( $v_i^k$ ) d'une fonction généralement non-linéaire, la fonction d'activation  $f(\cdot)$ .

$$s_i^k = f(\mathbf{u}^k \mathbf{w}_i)$$

##### 3.2.3.1.3. LE RESEAU PERCEPTRON MULTICOUCHE

Les réseaux utilisés dans ce travail sont fondés sur le modèle appelé *perceptron multicouche* comportant des entrées exogènes et, dans le cas des réseaux bouclés, un retour de la sortie vers l'entrée de la grandeur de sortie mesurée ou simulée. Les différents types de réseaux ont des propriétés spécifiques que nous présentons dans la suite afin que le choix d'un modèle ou d'un autre soit plus clair. Pour être plus explicite, nous vous proposons une analogie avec l'estimation d'une grandeur de tous les jours afin de présenter simplement et de manière très intuitive quels sont les avantages et les inconvénients des différents types de modèles utilisés. Considérons par exemple que nous voulons estimer le prix de la baguette demain : au jour  $j$ . Trois solutions s'offrent à nous : la première consiste à calculer ce prix en fonction de toutes les variables qui interviennent dans ce calcul : le prix de la farine, de l'énergie, le salaire du boulanger, les différents amortissements, etc.

Toutes ces variables doivent être connues et amènent à un calcul assez complexe en soi et à une estimation détaillée de tous les coûts intervenant. En hydrologie cela consiste à calculer, par exemple, le débit en fonction des pluies, températures, humidité du sol, pentes, végétation, ... c'est le cas du réseau statique présenté dans la section suivante. Pour un modèle à base physique, il faudrait en plus considérer les propriétés de l'aquifère : porosité, perméabilité, connectivité..., qui sont difficilement mesurables de façon exhaustive pour un hydrosystème karstique.

La seconde méthode considère que l'on peut partir du prix de la baguette que l'on a estimé aujourd'hui pour en déduire le prix de la baguette au jour  $j$ . En fonction d'une tendance grossière on peut ajouter un terme correcteur à ce prix estimé. C'est le calcul que fait le modèle récurrent. Si le prix estimé aujourd'hui est très imprécis, l'estimation au jour  $j$  le sera également. Les imprécisions, ou erreurs, peuvent se compenser ou se cumuler. Si elles se cumulent le prix de la baguette estimé peut diverger. Le modèle récurrent peut donc être instable. En hydrologie, il s'agit de calculer le débit en fonction des débits estimés précédents, et des variables de précipitation ; c'est ce que propose par exemple la loi de Maillet, ou toute équation aux différences (équation différentielle discrétisée) faisant intervenir les incréments de débits.

La dernière méthode proposée considère que le plus simple est d'estimer le prix de la baguette au jour  $j$  en fonction du prix de la veille. C'est ce que nous faisons dans la vie de tous les jours. C'est la méthode la plus fiable, jamais instable, mais qui nécessite de disposer d'une mesure de la variable de sortie utilisée en entrée du modèle. C'est le modèle dirigé par la mesure, ou non-récurrent, qui est décrit dans la suite. En hydrologie ce modèle estime le débit en fonction du débit de la veille et des précipitations reçues, avec éventuellement d'autres variables utiles (évapotranspiration, ...).

## RESEAU STATIQUE

---

Le réseau statique est un perceptron multicouche qui ne reçoit en entrée que des variables exogènes. Contrairement aux réseaux présentés dans la section suivante, le réseau statique ne reçoit pas d'information sur sa sortie aux temps précédents. Il est donc nécessaire de fournir au modèle suffisamment d'informations exogènes pour lui permettre d'estimer son état et ses variations.

$$s^k(\mathbf{u}^k, \mathbf{w}) = g_{NN}(u^k, \dots, u^{k-m}, \mathbf{w})$$

Avec  $s^k$  la sortie calculées par le modèle à l'instant  $k$ ,  $\mathbf{u}^k$  le vecteur d'entrées et  $\mathbf{w}$  le vecteur de paramètres associés,  $g_{NN}$  la fonction non-linéaire implémentée par le modèle, et  $m$  la taille de la fenêtre glissante des variables.

## RESEAU RECURRENT

---

Le réseau récurrent reçoit en entrée des variables exogènes, mais aussi une information sur sa sortie : le débit simulé aux temps précédents  $s^{k-1}, \dots, s^{k-m}$ .

$$s^k(s^{k-1}, \mathbf{u}^k, \mathbf{w}) = g_{NN}(s^{k-1}, \dots, s^{k-r}, u^k, \dots, u^{k-m+1}, \mathbf{w})$$

Avec  $s^k$  la sortie calculées par le modèle à l'instant  $k$ ,  $\mathbf{u}^k$  le vecteur d'entrées et  $\mathbf{w}$  le vecteur de paramètres associés,  $g_{NN}$  la fonction non-linéaire implémentée par le modèle, et  $m$  la taille de la fenêtre glissante des variables.

## RESEAU NON-RECURRENT

---

Le réseau non-récurrent (dirigé par la mesure), reçoit en entrée des variables exogènes, et une information sur la variable de sortie mesurée aux temps précédents  $q^{k-1}, \dots, q^{k-m}$ .

$$s^k(\mathbf{u}^k, \mathbf{w}) = g_{NN}(q^{k-1}, \dots, q^{k-r}, u^k, \dots, u^{k-m}, \mathbf{w})$$

Avec  $s^k$  la sortie calculée par le modèle à l'instant  $k$ ,  $\mathbf{u}^k$  le vecteur d'entrées exogènes,  $q^{k-1}$  la variable de sortie mesurée au temps précédent et  $\mathbf{w}$  le vecteur de paramètres associés aux entrées,  $g_{NV}$  la fonction non-linéaire implémentée par le modèle, et  $m$  la taille de la fenêtre glissante des variables.

### 3.2.3.2. CONTRAINDRE ET EXPLOITER LES MODELES

#### 3.2.3.2.1. BOITES GRISES

Le principe de modélisation par boîte grise, ou semi-physique, consiste à utiliser les connaissances disponibles tout en conservant la souplesse d'un modèle aux paramètres ajustables. Les contraintes opérées peuvent affecter les variables d'entrée et leur fenêtre temporelle, mais aussi les paramètres du modèle. Il est possible d'introduire des équations différentielles (avec un formalisme neuronal) pour représenter des processus physiques (diffusivité, transport, etc.). Ce type de modèle possède donc une part conceptuelle et une part à base physique.

#### 3.2.3.2.2. BOITES TRANSPARENTES

Les boîtes transparentes sont basées sur la représentation du processus modélisé sous forme de schéma-bloc. L'utilisation de sous-réseaux correspond à un schéma conceptuel et chaque sous-réseau est réalisé par un perceptron multicouche du fait de sa propriété d'approximation universelle, ou par un seul neurone, pour diminuer le nombre de paramètres ajustables. L'objectif est d'utiliser l'information de sortie des sous-réseaux pour interpréter un ou plusieurs processus hydrodynamiques. La boîte est rendue transparente car on peut y observer des signaux simulés pour lesquels on a supposé un sens physique (Johannet et al., 2008b).

#### 3.2.3.2.3. ACQUISITION D'INFORMATION

La méthodologie KnoX (Kong-A-Siou et al., 2013) s'intéresse à l'interprétation des paramètres affectés par le modèle aux entrées. Cette méthodologie peut être utilisée pour estimer si des fonctions calculées à partir de paramètres sont cohérentes avec les hypothèses du modèle conceptuel du fonctionnement hydrodynamique. L'exploitation des valeurs des paramètres calculés par le modèle est un des points majeurs de ce travail de thèse dont l'objectif est de rendre interprétable le modèle que l'on a préalablement validé.

### 3.2.4. CONCLUSIONS SUR LES RESEAUX DE NEURONES APPLIQUES A LA MODELISATION HYDRODYNAMIQUE DES KARSTS

L'article présenté et commenté dans cette première partie du chapitre 3 a permis d'aborder le fonctionnement des réseaux de neurones en tant que modèles hydrodynamiques appliqués aux hydrosystèmes karstiques.

Nous avons donc vu que les méthodes d'apprentissage statistique sont des outils pertinents pour la modélisation et l'étude du fonctionnement de systèmes naturels complexes et non-linéaires. Ce début de chapitre aborde donc les principales caractéristiques des différents modèles inspirés du perceptron multicouche (modèles statique, récurrent et non-récurrent). Dans les applications qui seront faites et présentées au chapitre 5, l'utilisation de ces différents modèles, associée à l'étude de leurs paramètres, servira à mieux comprendre leur fonctionnement. L'objectif final étant de pouvoir choisir le modèle le plus adapté aux objectifs fixés. C'est-à-dire que certains modèles, comme le modèle non-récurrent, vont être plus performants et plus stable, tandis que le modèle statique aura généralement de moins bonnes performances mais sera susceptible de fournir des informations différentes sur la relation entrée-sortie.

Cette démarche d'étude du fonctionnement des modèles et de l'information nécessaire pour les alimenter vise aussi à apporter des alternatives à la méthode de sélection des fenêtres temporelles des entrées par validation



croisée. En effet, cette étape est relativement chronophage surtout lorsque le nombre de variables à investiguer est grand.

Une partie des méthodes présentées ici sera donc appliquée au chapitre 5 pour modéliser et étudier le fonctionnement hydrodynamique de la source du Lez, et plus particulièrement la relation entrée-sortie (pluie-débit).

### 3.3. RESEAUX DE NEURONES ET NON-STATIONNARITE

#### 3.3.1. INTRODUCTION

Nous avons évoqué dans le chapitre 1 que les hydrosystèmes karstiques pouvaient être sujets à différents types de non-stationnarités : eustatisme, changements climatiques, colmatages... Cette variabilité du système est susceptible de s'exprimer à différentes échelles temporelles. Pour tenir compte de ces différents types de changement, il est utile de disposer d'outils adéquats. L'article (Taver et al., 2014) ci-après, décrit l'utilisation des outils d'adaptativité et d'assimilation de données associés à l'utilisation des réseaux de neurones. Sa rédaction s'inscrit dans le cadre de l'édition d'un numéro spécial de la revue Hydrological Sciences Journal dédié aux résultats du workshop de l'IAHS : « Knowledge for the future » (Göteborg, juillet 2013).

Les deux hydrosystèmes étudiés, choisis parmi ceux proposés dans le cadre du workshop (Göteborg, juillet 2013), ne sont pas des karsts mais sont variables dans le temps ou reçoivent des entrées non-stationnaires. Les deux cas étudiés sont très différents, de même que les non-stationnarités qui les affectent. En effet, le bassin expérimental de Fernow (0,2 Km<sup>2</sup>) illustre une modification du système lui-même (modification de la couverture végétale) et de son fonctionnement. Dans le cas de la Durance, c'est la température, une des variables d'entrée, qui est modifiée par le changement climatique.

L'un des objectifs de cet article est d'étudier l'influence des méthodes d'adaptativité et d'assimilation de données sur l'estimation du débit en sortie de l'hydrosystème considéré en conditions non-stationnaires. La première méthode modifie les paramètres du modèle et donc la façon dont celui-ci prend en compte ses entrées. Cette méthode d'adaptativité semble donc être la plus en adéquation avec une modification de l'hydrosystème, c'est-à-dire une modification de la façon dont le système transforme ses entrées. L'assimilation de données est une méthode qui consiste à modifier les entrées pour améliorer l'estimation de la sortie. On suppose dans ce cas que le modèle prend bien en compte ses entrées mais que celles-ci ne sont pas correctes (imprécises ou incomplètes), c'est le cas des modèles météorologiques dont les entrées, issues de modèles de prévision, sont ajustées en temps réel à partir de mesures récentes. L'assimilation de données est donc un outil qui peut permettre de prendre en compte des changements de forçages sans pour autant modifier le fonctionnement du système.

Cet article illustre l'utilisation de deux modèles, récurrent (recurrent) et non-récurrent (feed-forward), auxquels vont être appliquées l'assimilation de données et l'adaptativité, et ce, pour chacun des bassins. Les résultats obtenus et les perspectives qu'ils ouvrent seront commentés après l'article.

#### 3.3.2. LES MODELES DE RESEAUX DE NEURONES NON-RECURRENTS ET RECURRENTS POUR MODELISER LES NON-STATIONNARITES EN UTILISANT L'ASSIMILATION DE DONNEES ET L'ADAPTATIVITE.

#### RESUME :

*Les réseaux de neurones (RN) sont largement répandus en hydrologie pour leurs propriétés d'approximation universelle et de parcimonie. Leurs performances durant la phase d'apprentissage sont très bonnes, et leurs capacités à généraliser peuvent être améliorées par l'utilisation de méthodes de régulation comme l'arrêt précoce et la validation croisée. Dans ce travail, deux types de modèles génériques sont implémentés : le*

*modèle non-récurrent et le modèle récurrent. A première vue, le modèle non-récurrent semble être plus efficace que le récurrent sur des bases de données non-stationnaires du fait de l'utilisation en entrée du modèle de l'information mesurée de l'état du système (débit mesuré) ce qui revient à une forme d'assimilation de données. Cette étude porte sur la faisabilité et l'efficacité l'assimilation de données et de l'adaptativité lorsqu'ils sont implémentés dans les modèles de réseaux de neurones récurrents et non-récurrents.*

*Dans le cadre du workshop de l'IAHS qui s'est déroulé à Göteborg (juillet 2013), les fonctionnements hydrologiques de deux bassins versants, de tailles différentes et sujets à différents types de non-stationnarités, vont être modélisés : i) le bassin versant de Fernow (0,2 km<sup>2</sup>), aux USA, affecté par une modification significative de la couverture végétale pendant la période d'étude, ii) le bassin versant de la Durance (2170 km<sup>2</sup>), en France, affecté par une augmentation de la température qui entraîne la diminution de l'extension des glaciers.*

*Deux méthodes ont été appliquées pour évaluer la capacité des RN à s'adapter à un ensemble de test : i) l'adaptativité, en utilisant les données observées pour adapter la valeur des paramètres en test réel ; ii) l'assimilation de données, en utilisant les données observées pour modifier les entrées imprécises en temps réel. L'objectif de l'étude est donc la simulation et non la prévision.*

*Ces travaux soulignent l'efficacité du modèle non-récurrent par rapport au modèle récurrent pour composer avec la non-stationnarité. Ils montrent aussi que l'adaptativité et l'assimilation de données améliorent considérablement le modèle récurrent, alors que l'amélioration est marginale pour le modèle dirigé dans les mêmes conditions. Finalement, cette étude suggère que l'adaptativité est efficace dans le cas de modifications du bassin versant, alors que, l'assimilation de donnée est plus adaptée aux cas de changement climatiques (modifications des entrées).*

# Feed-forward vs recurrent neural network models for non-stationarity modelling using data assimilation and adaptivity

V. Taver<sup>1,2</sup>, A. Johannet<sup>1</sup>, V. Borrell-Estupina<sup>2</sup>, S. Pistré<sup>2</sup>

<sup>1</sup> Ecole des Mines d'Alès, 6 avenue de Clavières, 30319 Alès Cedex, France

[anne.johannet@mines-ales.fr](mailto:anne.johannet@mines-ales.fr)

<sup>2</sup> Université Montpellier II, Hydrosociences Montpellier, Place E. Bataillon, 34095 Montpellier Cedex 5, France

**Abstract** Artificial neural networks (ANN) are nonlinear models widely investigated in hydrology due to their properties of universal approximation and parsimony. Their performance during the training phase is very good, and their ability to generalize can be improved by using regularization methods such as early stopping and cross-validation. In our research, two kinds of generic models are implemented: the feed-forward model, and the recurrent model. At first glance, the feed-forward model would seem to be more effective than the recurrent one on non-stationary datasets, because measured information on the state of the system (measured discharge) is used as input, thereby implementing a kind of data assimilation. This study investigates the feasibility and effectiveness of data assimilation and adaptivity when implemented in both feed-forward and recurrent neural networks. Based on the IAHS workshop held in Göteborg (July 2013), the hydrological behaviour of two watersheds of different sizes and different kind of non-stationarity will be modelled: (a) the Fernow watershed (0.2 km<sup>2</sup>) in the USA, affected by significant modifications in land cover during the study period, and (b) the Durance watershed (2170 km<sup>2</sup>) in France, affected by an increase in temperature that is causing a decrease in the extent of glaciers. Two methods were applied to evaluate the ability of ANN to adapt on the test set: (i) adaptivity using observed data to adapt parameter values in real time; (ii) data assimilation using observed data to modify inaccurate inputs in real time. The goal of the study is thus reanalysis and not forecasting. This study highlights how effective the feed-forward model is compared to the recurrent model for dealing with non-stationarity. It also shows that adaptivity and data assimilation improve the recurrent model considerably, whereas improvement is marginal for the feed-forward model in the same conditions. Finally, this study suggests that adaptivity is effective in the case of changing conditions of the watershed, whereas data assimilation is better in the case of climate change (inputs modification).

**Key words** neural network model; adaptivity; data assimilation; non-stationarity

## Modèles de réseaux de neurones non récurrents vs récurrents pour la modélisation non-stationnarité en utilisant l'assimilation des données et l'adaptabilité

**Résumé** Les réseaux de neurones formels sont de plus en plus utilisés en hydrologie du fait de leurs propriétés d'approximation universelle et de parcimonie. Si leurs performances en apprentissage sont excellentes, leur capacité à généraliser à un ensemble inconnu doit être préservée grâce à l'utilisation de méthodes de régularisation, comme l'arrêt précoce et la validation croisée. Dans ce travail deux types de modèles ont été étudiés : un modèle non récurrent et un modèle récurrent. De prime abord, le modèle non récurrent qui reçoit en entrée le débit mesuré comme variable d'état du système, est plus efficace pour simuler le débit de bassins versants stationnaires. L'utilisation en entrée de la variable observée est souvent considérée comme un type d'assimilation de données. Ainsi le travail ici présenté s'intéresse à comparer la faisabilité et la performance de l'assimilation de données comme de l'adaptativité sur les deux types de modèles : récurrent et non récurrent. Les bassins d'étude sont issus de ceux proposés lors du workshop de l'IAHS qui s'est tenu à Göteborg en juillet 2013. Deux bassins différents tant par leur dimension que par le type de non-stationnarité qui les affecte ont été choisis comme étude de cas : (a) le bassin de Fernow (USA) est petit (0.2 km<sup>2</sup>) et a subi un changement

d'occupation du sol, tandis que (b) le bassin de la Durance (France) est beaucoup grand (2170 km<sup>2</sup>) et subit une augmentation de ses températures causant une fonte des glaciers. En sus des capacités d'adaptation du modèle non récurrent précédemment cité, deux types d'adaptation aux changements ont été étudiés : (i) l'adaptation visant à modifier les paramètres du modèle en temps réel, ou adaptativité ; et (ii) l'adaptation visant à corriger des entrées très incertaines en temps réel ou « assimilation de données ». Il apparaît tout d'abord que le modèle le plus efficace pour simuler les débits est le modèle non-récurrent utilisant les débits mesurés passés, néanmoins les modèles récurrents peuvent être très significativement améliorés en utilisant l'adaptativité ou l'assimilation de données, tandis que le modèle non-récurrent est assez peu sensible à ces adaptations. De plus il apparaît, de manière cohérente, que l'adaptativité est plus adaptée lorsque la non-stationarité affecte le bassin, tandis que l'assimilation de donnée est mieux adaptée lorsque la non-stationnarité affecte les variables d'entrée.

**Mots clefs** modèle de réseau neuronal ; adaptabilité ; assimilation de données ; la non-stationnarité

## 1. INTRODUCTION

The real world is not in a state of equilibrium, and anthropogenic forces are currently having a stronger effect than natural forces in changing the climate. Likewise, a great challenge in hydrology is the ability of hydrological models to work satisfactorily, particularly in changing conditions.

In this context, the IAHS workshop “Knowledge for the future” (Göteborg, July 2013) proposed to evaluate the ability of models used in hydrology to deal with non-stationarity in the common datasets provided to participants. In our study, two different basins with different unsteady conditions were picked from the common database and investigated using artificial neural network modelling: (i) the Fernow watershed (0.2 km<sup>2</sup>) in the USA, affected by modifications in land cover during the study period, and (ii) the Durance watershed (2170 km<sup>2</sup>) in France, affected by an increase in temperature that is causing a decrease in glacier coverage.

Based on the brain's ability to learn behaviour from examples and observations, neural-based models seem to be able to adapt to changing environments (Coulibaly *et al.* 2005, Coulibaly and Baldwin 2008). Common properties of Artificial Neural Networks (ANN) models are their ability: i) to learn the watershed functioning based on inputs and outputs alone; ii) to deal with nonlinearity; iii) to generalize from a training set to a supplementary dataset never presented to the model. This important property is called *generalization*. Because of this property, ANN models were considered to be suitable for this workshop.

Adapting to a changing environment requires up-to-date information and a method for taking this information into account within the model.

When using neural networks, the feed-forward model is usually designed on the basis of up-to-date information. In this model, input variables are made up of observed variables (rainfall, climatic variables, and previous observed discharge). This model is the one most commonly used because it provides very good results (Coulibaly *et al.* 1999). Its drawback is that it requires very recent information not available in every case: discharge measurement. If changes in the statistical properties of the input variables occur, they are automatically taken into account by the model. In this paper, this kind of model is referred to as a feed-forward model. The inputting of observed discharge in the model is also associated with a way of implementing data assimilation. Another more innovative method applies to another kind of model known as the recurrent model, which is used when previous observed discharge is not

available, or of poor quality. Its input variables are observed variables (rainfall, climatic variables), plus its previous estimated discharges. The model is thus a nonlinear dynamic model, which might be adapted to non-stationarity (Haykin and Li 1995, Haykin 1999, Coulibaly *et al.* 2000). Depending on what kinds of changes occur in the basin, two kinds of modifications can be applied to ANN model in order to adapt to these changes: (i) if the watershed is modified (forest destruction, ...), the model can be adapted in real time by modifying its parameters by means of permanent training. This configuration is well known in adaptive signal processing and called *adaptivity*. In the second case, (ii) if the watershed is not modified, but only the input signals are (climate change), which means the model must be used in a new state-place configuration, the model may not respond correctly. In this configuration, it is possible, using the unmodified model, to modify the inputs in order to maintain the ability to estimate the actual discharge correctly based on updated input values. In this paper, this second way of dealing with a non-stationary environment is called data assimilation, because it uses the same approach as the data assimilation method usually applied in meteorology (Le Dimet and Talagrand 1986).

In order to follow the 3 levels of the methodology suggested in the IAHS workshop (Thirel *et al.* 2014), 2 kind of generic ANN models (feed-forward and recurrent) and two additional methods (for each model) are used. We thus obtain 6 kinds of models (feed-forward, feed-forward with adaptivity, feed-forward with data assimilation; recurrent, recurrent with adaptivity, recurrent with data assimilation) to deal with non-stationary with neural networks.

The presentation of selected catchments and protocol is done in the first section. After that the paper presents neural network modelling, focusing on neural network computing principles and design. The next section discusses methods for dealing with non-stationarity. Then we show how ANN models and methods can be used to deal with unsteady conditions in selected watersheds. Finally, results of this study are discussed.

## **SELECTED CATCHMENTS**

We applied neural network modelling to two of the 14 catchments studied in the workshop (IAHS workshop section 2013; Thirel *et al.* 2014). Our aim was to compare the performance of neural network models in very different conditions. Fernow is the smallest catchment with an experimental forest, which modifies its hydrological behaviour. The Durance catchment is one of the largest in the dataset, and its inputs are modified by climate change. Both types of non-stationarity (process and environment) were thus assessed.

### **1.1. The Fernow experimental forest, watershed 6**

This watershed, presented in Thirel *et al.* (2014) is the smallest in the database. It is a 0.22 km<sup>2</sup> catchment situated in the USA at an elevation of around 800 m and a mean slope of 35% (Edwards and Wood 1994). The difficulties involved in modelling the behaviour of this catchment are due to the: *i*) unsteady conditions in the experimental forest; *ii*) lack of meteorological inputs representing the solid fraction of precipitation, snowpack, and snowmelt; *iii*) during the last summer period, evapotranspiration and soil storage data could not be efficiently supplied.

Considering the slope and the small size of this catchment, it is probable that the daily sampling period would not be adapted to the response time of the basin, at least during the wet season. Nevertheless, the challenge was to accurately model this unsteady catchment which has a modified hydrological behaviour over a long time period (50 years).

## 1.2. The River Durance at *La Clapière*

This mountainous watershed, situated in the French Alps, covers around 2,170 km<sup>2</sup>. This catchment had already been modelled (Lafaysse *et al.* 2011). The difficulties involved in modelling the behaviour of this catchment are due to: *i*) spatial variability of exogenous variables is not well represented; *ii*) lack of data about the extension and melting of glaciers, solid fraction of precipitation, snowpack, and snowmelt; *iii*) unsteady conditions linked to temperature increases, which contribute to decreasing the size of glaciers. The hydrological behaviour depends on many natural variables such as rainfall, snowmelt, glacier melt, and evapotranspiration.

Contrary to Fernow, the unsteady conditions in the Durance catchment are associated with modifications of its variables.

## 2. NEURAL NETWORK MODELLING

### 2.1. Introduction

In order to model discharge in various kinds of catchments, an easily transposable model must be used. In this context, a systemic approach seems to be valuable, because it only requires an input-output dataset. H.R. Maier and G.C. Dandy (2000) underline that artificial neural network models have been widely used to investigate nonlinear relationships between hydrological variables effectively. In the recent past, neural network modelling has been used increasingly to study hydrological systems. For example, Pereira Filho and Dos Santos (2006) worked on an urban catchment basin, Kong-A-Siou *et al.* (2012) (2013) modelled rainfall relationships in karst systems for prediction or for improving the knowledge on these aquifers, and Artigue *et al.* (2012) worked on flash flood forecasting in poorly gauged basins. All of these studies have contributed to the development of design and methods for improving the performance of neural networks in modelling hydrological systems. In this context, we will briefly present specific aspects of neural network model design.

### 2.2. Definition of neuron

Inspired by the human brain, “neurons” are mathematical operators, which learn an input-output relationship during a training step. To begin, the neuron performs two actions. First, in the framework of dynamic system modelling dealing with time dependant signals, it computes its potential  $v_i^k$ , at discrete time  $k$ , which is the dot product of its parameters and the input variables vector at time  $k$ . Next, the neuron applies a nonlinear function  $f(\cdot)$ , also called an activation function, to the potential in order to calculate its output ( $s_i^k$ ). If  $\mathbf{w}_i$  represents the vector of parameters linking the row vector of input variables  $\mathbf{u}^k$  to the neuron  $i$ , one can define:

$$\mathbf{v}_i^k = \mathbf{u}^k \mathbf{w}_i, \text{ and } s_i^k = f(\mathbf{u}^k \mathbf{w}_i) \quad (1)$$


This description of how a neuron functions will be useful in Section 4.

## 2.3. Model design

### 2.3.1. Multilayer perceptron

The neural network model is a combination of neurons with a specific architecture. In this study, we preferred to use the multilayer perceptron for its properties of parsimony (Barron 1993) and universal approximation (Hornik 1989). Universal approximation property means that any nonlinear and derivable function can be identity by this generic architecture. It is a proof of existence; the specific model must be built by the calculation of the parameters.

The multilayer perceptron (illustrated in Fig. 1) is basically composed of two layers: a hidden layer of  $n_h$  nonlinear neurons, and an output layer, which corresponds to a single linear neuron. Hornik (1989) has also shown that the accuracy of the identification increases with the number of hidden nonlinear neurons. Depending on the existence of feedback two generic models can be proposed: the feed-forward and the recurrent models. Nerrand et al. (1993) defines the properties of these generic models: feed-forward model is able to predict future values one-step ahead, while recurrent model is able to predict future values over an indefinite lead time provided the existence of prediction of its input variables.



**Fig. 1** Multilayer perceptron.

### 2.3.2. Feed-forward model

The feed-forward model is a multilayer perceptron fed by only exogenous inputs. Specifically, added to climatic data (rainfall, temperature, evapotranspiration, ...), this model receives measurements of discharge at previous times ( $k-1, \dots$ ). These inputs can be considered as providing the state of the watershed. This model can be mathematically explained as:

$$s^k(\mathbf{u}^k, \mathbf{w}) = g_{NN}(q^{k-1}, \dots, q^{k-r}, \mathbf{u}^k, \dots, \mathbf{u}^{k-m+1}, \mathbf{w}) \quad (2)$$

where  $s^k$  is the estimated discharge,  $g_{NN}$  is the nonlinear function implemented by the neural network,  $k$  is the discrete time (sampled each time-step of the dataset),  $q^k$  is the measured discharge,  $\mathbf{u}^k$  is the vector of exogenous variables (rainfalls, temperature, etc),  $r$  is the order of the model,  $m$  is the width of the sliding time window of exogenous variables,  $\mathbf{w}$  is the matrix of parameters.

### 2.3.3. Recurrent model

When discharge information is not available for the entire period, the discharge measurements can be replaced by the discharge estimations, at the previous times, computed by the model.

The advantage of this method is that it takes better account of the hydrological behaviour of the system. Nevertheless, it is generally less effective for predicting future discharge as illustrated by Artigue *et al.* (2012).

The recurrent model can be stated mathematically as:

$$s^k(s^{k-1}, u^k, \mathbf{w}) = g_{NN}(s^{k-1}, \dots, s^{k-r}, u^k, \dots, u^{k-m+1}, \mathbf{w}) \quad (3)$$

with the same notations than previously.

## 2.4. Training

Training allows the parameters to be calculated. It consists in using a training rule to minimize a cost function iteratively. In this study, the mean square error function ( $J$ ) between observed and simulated discharge, at each presentation of the training database, is used as a cost function. It can be stated mathematically, as:

$$J = \sum_{k=1}^{k_{\max}} (q^k - s^k(\mathbf{w}))^2 \quad (4)$$

where  $q^k$  is the observed discharge at discrete time  $k$ , and  $s^k$  is the simulated discharge at time  $k$ .  $\mathbf{w}$  corresponds to the model parameters.

Training is performed using the Levenberg-Marquard method (Hagan and Menhaj 1994). Dreyfus (2005) underlines that this algorithm returns a good approximation of the cost function. During the training, the model minimizes the cost function at each iteration (for the whole set of training database) by modifying the model parameters. Usually, parameters are constant for each iteration of training. The training step could lead to overfitting, which means poor generalization ability, due to the bias-variance dilemma (Geman *et al.* 1992), which is one major trap of machine learning. The bias-variance dilemma expresses the notion that the error calculated on the training set is not a good estimator of the generalization error. This effect is not constant: it increases with the complexity of the model (number of free parameters depending on the number of inputs and of hidden neurons). More accurately, when the number of free parameters increases, the bias of the model diminishes (mean error), while the variance of the error increases. In order to prevent this effect, regularization methods can be used. Furthermore, the quality of the solution found by means of training is very sensitive to the initial value of the vector of parameters ( $\mathbf{w}$ ). The best value for this initial vector is chosen as explained in section 3.6.

## 2.5. Regularization methods

As previously suggested, regularization methods can be viewed as methods for minimizing variance of the error. Kong-A-Siou *et al.* (2011), and Toukourou *et al.* (2009) study several methods and propose a combination of cross-validation and early stopping.

### 2.5.1. Passive regularization method: cross-validation

Passive regularization methods do not apply to models during training: they are used for selecting models. Proposed by Stone (1974), cross-validation was applied by Toukourou *et al.* (2009) for selecting model complexity and input sliding time windows of variables.



Cross-validation involves dividing the calibration period in  $V$  subsets. The model training is done on  $V-1$  subset and the generalization error is computed on the disjointed subset. This step is applied on each subset in turn in order to provide the *cross-validation score*, which reveals the ability of the model to generalize to an unknown subset. Minimizing variance of the error is thus performed by selecting the model with the smallest variance.

### **2.5.2. Active regularization method: early stopping**

Early stopping was presented by Sjöberg *et al.* (1995) as a regularization method. It is performed during the training step. A subset independent from the training set is defined and called the "stop set". During the training, the cost function  $J$  is calculated on both training and stop sets. The training procedure is stopped when the cost function calculated on the stop set reaches its minimum. At this presentation  $\pi$ , the model reaches its best generalization performance thereby avoiding overtraining. Toukourou *et al.* (2011) and Bowden *et al.* (2002) suggest that it is important to use a stop set representative of the desired behaviour. Nevertheless, as the protocol and datasets of the workshop were imposed, no special care could be taken to select a representative stop set. The stop set was chosen outside of calibration (training) and validation (testing) periods. In these conditions, stop sets are not *a priori* especially representative of the dataset.

### **2.6. Model selection**

As suggested by the bias variance dilemma, the model complexity must be adjusted in order to obtain the best performance in terms of generalization. The selection of the best architecture was made in this study using cross-validation: several models were generated with varying degrees of complexity (by varying  $m$ ,  $r$ , the lengths of sliding time windows of exogenous variables, and  $n_h$  the number of hidden neurons). Thus the best model (minimizing the variance) was chosen. The cross-validation score (Kong-A-Siou *et al.* 2011) is based on the Nash score (5.2.1) for this study. Cross-validation was also used to choose the best initial value of the parameters  $\mathbf{w}$  before training.

### **2.7. Evaluation of the quality of the model**

Finally, after selecting the complexity and the best initialisation, which both require 2 independent datasets (training, stopping) to be defined, the training is performed based on the training set and starting from the best initialisation. The quality of the model is then assessed using a third independent dataset. This set is called the 'test set' (generally the term validation set is used); however, we preferred to use the term 'test set' in order to prevent any confusion with the validation sets of the cross-validation. Generally, for the test set we recommend using a set containing extreme events (an extreme flood or extremely low water level) in order to assess the ability of the model to generalize on all the different cases in the database (Toukourou *et al.*, 2011). In our study, however, the test set was imposed by the workshop protocol.

## **3. METHODS FOR DEALING WITH NON-STATIONARITY USING NEURAL NETWORKS**

Using ANN models consists in a global, or systemic, approach. It supposes that all information about the system is contained in the input and output signals. This explains why no indicators of non stationarity were used in this study.

Several methods were developed in order to adapt the model to non-stationary processes (evolving processes, for instance ageing), or non-stationary environmental data (changing environment). Each can be considered using different mathematical formulations. The first is usually referred to as “adaptivity” in the science of systems. It is not novel, even if it is not used in hydrology. Meanwhile, the second one was first used in meteorological applications such as data assimilation: to the best of our knowledge, it is novel in the field of hydrology as well as for neural networks.

### 3.1. Adaptivity

In the case of adaptivity, the process to model is considered as changing. Parameters of the model must thus be changed iteratively based on input-output data. The principle is to move toward permanent training by minimizing the same error function as the one presented in equation (4). The Levenberg-Marquardt (Hagan and Menhaj 1994; Dreyfus, 2005) rule is used for that purpose. This method is iterative and uses the Hessian matrix containing the second derivative of the estimated output of the model  $s^k$  with respect to the parameters to adapt  $\mathbf{w}^k$ . One can note that, in the context of adaptivity, model parameters are able to change after the training phase, they must thus depend on the discrete time  $k$  during the test phase. One powerful assumption of the Levenberg-Marquardt is that the second derivative can be approximated as the product of the two first derivatives. Thus, only first derivatives have to be calculated.

For the sake of adaptivity implementation, a new cost function to minimise during permanent training is defined thanks to equation (4). This cost function can be written as:

$$J^k = \sum_{p=0}^{\tau-1} \left( q^{k-p} - s^{k-p}(\mathbf{u}^{k-p}, \mathbf{w}) \right)^2 \quad (5)$$

where  $p$  is the index representing past values of discrete time, and  $\tau$  is the maximum length of the sliding window of examples (couple  $\{\mathbf{u}^k, q^k\}$ ) taken into account in the permanent training.

The well-known method of back-propagation (Rumelhart *et al.* 1986) can be used to calculate the first derivative of the output variable with respect to the specific parameter to adapt,  $w_{ij}^k$ . The principle of back-propagation is that the derivative of the output variable  $s^k(\mathbf{u}^k, \mathbf{w}^k)$  with respect to the parameters to adapt  $\mathbf{w}^k$ :

$$\frac{\partial s^k(\mathbf{u}^k, \mathbf{w}^k)}{\partial w_{ij}^k}$$

can be chained through the multilayer perceptron from the output towards the inputs as exemplified in the Appendix.

By means of the operations involved in the neural model (Appendix), the computation of the previous term can be decomposed, for each neuron  $i$ , as:

$$\frac{\partial s^k(\mathbf{u}^k, \mathbf{w}^k)}{\partial w_{ij}^k} = \frac{\partial s^k(\mathbf{u}^k, \mathbf{w}^k)}{\partial v_i^k} \frac{\partial v_i^k(\mathbf{u}^k, \mathbf{w}^k)}{\partial w_{ij}^k} \quad (6)$$

As stated in equation (1), the second term in the equation is equal to the input variable  $u_j^k$ , so the derivative becomes:

$$\frac{\partial s^k(\mathbf{u}^k, \mathbf{w}^k)}{\partial w_{ij}^k} = \frac{\partial s^k(\mathbf{u}^k, \mathbf{w}^k)}{\partial v_i^k} u_j^k \quad (7)$$

This expression is the one generally used to compute the derivatives for each parameter of each neuron  $i$  at each time step  $k-p$  ( $p=0, \tau-1$ ) at time  $k$  in order to build the Hessian matrix, and is the one used in this study. Thanks to Hessian matrix, Levenberg-Marquardt rule is applied to adapt the parameters.

From a practical point of view, several meta-parameters were introduced to control the permanent training:  $\tau$  represents the window of past values on which the minimization is performed. This minimization can be applied at each time step, or every  $T$  time-step ( $T$  is the interval between two successive adaptations). The third meta-parameter introduced is equivalent to a gradient rate  $\mu$ . It quantifies the importance of the increment to apply to the parameters.

### 3.2. Data assimilation

Data assimilation can be applied to neural networks (Van Den Boogaard and Mynett 2004), as it has been in the field of meteorology using the formalism of Kalman filters. The modification of the input  $u_j^k$  can also be performed using the variational formalism (Le Dimet and Talagrand 1986) using the Levenberg-Marquardt algorithm, and consequently the computation of the derivative of  $s^k$  with respect to a specific input variable to adapt  $u_j^k$ . As the neural network under consideration is fully derivable, it is easy to compute the derivative of the output value with respect to the input variables as well as the derivative was calculated with respect to the parameter  $w_{ij}$ . When applying data assimilation in order to adapt the input variable  $u_j^k$ , one considers that parameters  $\mathbf{w}$  are constant. Data assimilation operates on test set, simulating a real time adaptation, the parameters  $\mathbf{w}$  have thus been calculated before by training. The derivative can be expressed as:

$$\frac{\partial s^k(\mathbf{u}^k, \mathbf{w})}{\partial u_j^k} = \frac{\partial s^k(\mathbf{u}^k, \mathbf{w})}{\partial v_i^k} \frac{\partial v_i^k(\mathbf{u}^k, \mathbf{w})}{\partial u_j^k} \quad (8)$$

Considering equation (1), previous expression can be re-written as:

$$\frac{\partial s^k(\mathbf{u}^k, \mathbf{w})}{\partial u_j^k} = \frac{\partial s^k(\mathbf{u}^k, \mathbf{w})}{\partial v_i^k} w_{ij} \quad (9)$$

Thus equation 10 makes it possible to improve the behaviour of the model by modifying the input variables. As in the case of adaptivity, several meta-parameters were introduced in order to better control the modification of the inputs. One has to select the specific input variable to adapt ( $u_i$ ), the equivalent of the gradient rate  $\mu$ , and  $T$ , the interval between two successive adaptations.

### 3.3. Feed-forward model

Previous methods can be applied to both the feed-forward and the recurrent models; nevertheless, it would appear that in the case of the feed-forward model fed by exogenous variables and previous observed output variables, applying previous observed output variables is a way to adapt the model to the current state of the system. For this reason, some authors consider that this kind of model implements data assimilation intrinsically. Nevertheless, in order to prevent confusion between data assimilation as it is presented in section 4.2, the simple feed-forward model fed by previous state variables will be referred to as the feed-forward model, and the recurrent or feed-forward models modified in real time according to the method presented in section 4.2 will be called the *feed-forward model with data assimilation*, or *recurrent model with data assimilation*.

## 4. METHODOLOGY

### 4.1. Levels of modelling

For each catchment, six calibration periods were defined (complete period,  $P_1$ ,  $P_2$ ,  $P_3$ ,  $P_4$ , and  $P_5$ ). The protocol, which is presented in Thirel et al. (2014, this issue), was divided in 3 levels of modelling (Table 1 and Table 2). The first level is for beginners. It consists in calibrating and validating on the complete period. The second level (advanced) is a kind of cross-validation, in which calibration is done for a single period (each period in turn), while validation is done for all the others periods. This approach provides information about the suitable periods for model calibration and the most difficult periods to test. The aim of third level (expert) modelling is to assess methods in changing conditions. Table 1 and Table 2 detail application of different model and corresponding level of the protocol.

Depending on the protocol used, it is possible to select the best model architecture for each calibration (training) period ( $r$ ,  $m$ ,  $n_h$ ). Nevertheless, as this is a highly time-consuming task, and because Bornancin-Plantier (2013) shows that the quality of the model depends mostly on its initialization, it was decided to select the complexity of the models (recurrent as well as feed-forward) for only one calibration period and to apply this architecture to all others models. However, the best initialisation of parameters was selected for each basin (2), each model (2), and each training period (6).

|                                     |                 | Validation = Testing (for ANN) |             |             |             |             |             |
|-------------------------------------|-----------------|--------------------------------|-------------|-------------|-------------|-------------|-------------|
|                                     |                 | Complete period                | $P_1$       | $P_2$       | $P_3$       | $P_4$       | $P_5$       |
| Calibration = Training<br>(for ANN) | Complete period | level 1                        |             |             |             |             |             |
|                                     | $P_1$           | level 2 & 3                    | level 2     | level 2 & 3 | level 2 & 3 | level 2 & 3 | level 2 & 3 |
|                                     | $P_2$           | level 2 & 3                    | level 2 & 3 | level 2     | level 2 & 3 | level 2 & 3 | level 2 & 3 |
|                                     | $P_3$           | level 2 & 3                    | level 2 & 3 | level 2 & 3 | level 2     | level 2 & 3 | level 2 & 3 |
|                                     | $P_4$           | level 2 & 3                    | level 2 & 3 | level 2 & 3 | level 2 & 3 | level 2     | level 2 & 3 |
|                                     | $P_5$           | level 2 & 3                    | level 2 & 3 | level 2 & 3 | level 2 & 3 | level 2 & 3 | level 2     |

**Table 1** Detail of the protocol: level 1, 2 and 3.

|                          | <b>Models<br/>(Recurrent and Feed-forward)</b> | <b>Additional methods (adaptivity<br/>and data assimilation)</b> |
|--------------------------|--|--|
| <b>Applied on</b>        | <i>all periods</i>                             | <i>validation period (test)</i>                                  |
| <b>Level of protocol</b> | <i>1 &amp; 2</i>                               | <i>3</i>   |

**Table 2** Detail of the protocol: models and additional methods.

#### 4.2. Evaluation of models

Three levels of evaluation were proposed for the protocol. The first and second levels correspond to primary (explained below) and secondary scores; the third level consists in graphical analysis of the results (scores and hydrographs). For this study, the primary scores and graphical analysis were chosen because of their simplicity and conciseness.

##### 4.2.1. Primary scores

Commonly used to assess the quality of a hydrological model, the Nash-Sutcliffe efficiency criterion ( $N_{SE}$ ; Nash and Sutcliffe, 1970) was used for all models and periods. This quadratic score is suitable for high flow evaluation, but for low flows, an adapted version of  $N_{SE}$  ( $N_{SE}^{low\ flows}$ ) has been proposed by Pushpalatha *et al.* (2012). It basically consists in calculating  $N_{SE}$  by replacing output variables by their inverse ( $s$  becomes  $1/(s + 0.01\overline{q^k})$ ) to give more importance to lower values. Because the values  $s^k$  near to zero value induce instabilities, they are removed under a predefined bound. This procedure induces inaccuracy and arbitrary bias in this criterion. The bound was provided by the protocol.

The  $N_{SE}$  is calculated as follows:

$$N_{SE} = 1 - \frac{\sum_{k=1}^n (q^k - s^k(\mathbf{u}^k, \mathbf{w}^k))^2}{\sum_{k=1}^n (q^k - \overline{q^k})^2}, \quad (10)$$

with the same notations than previously,  $n$  is the number of samples in the set on which the Nash criterion is calculated.

Bias, denoted  $B$ , was also used for model evaluation:

$$B = \sum_{k=1}^n \frac{s^k(\mathbf{u}^k, \mathbf{w}^k)}{q^k}, \quad (11)$$

with the same notations as above. Bias provides information on mean relative error. It represents the relative error in terms of volume.

The  $N_{SE}$  for low flows is calculated as follows:

$$N_{SE \text{ low flows}} = 1 - \frac{\sum_{k=1}^n \left( \frac{1}{q^k + 0.01\overline{q^k}} - \frac{1}{s^k(\mathbf{u}^k, \mathbf{w}^k) + 0.01\overline{q^k}} \right)^2}{\sum_{k=1}^n \left( \frac{1}{q^k + 0.01\overline{q^k}} - \frac{1}{q^k + 0.01\overline{q^k}} \right)^2}, \quad (12)$$

with the same notations as above.

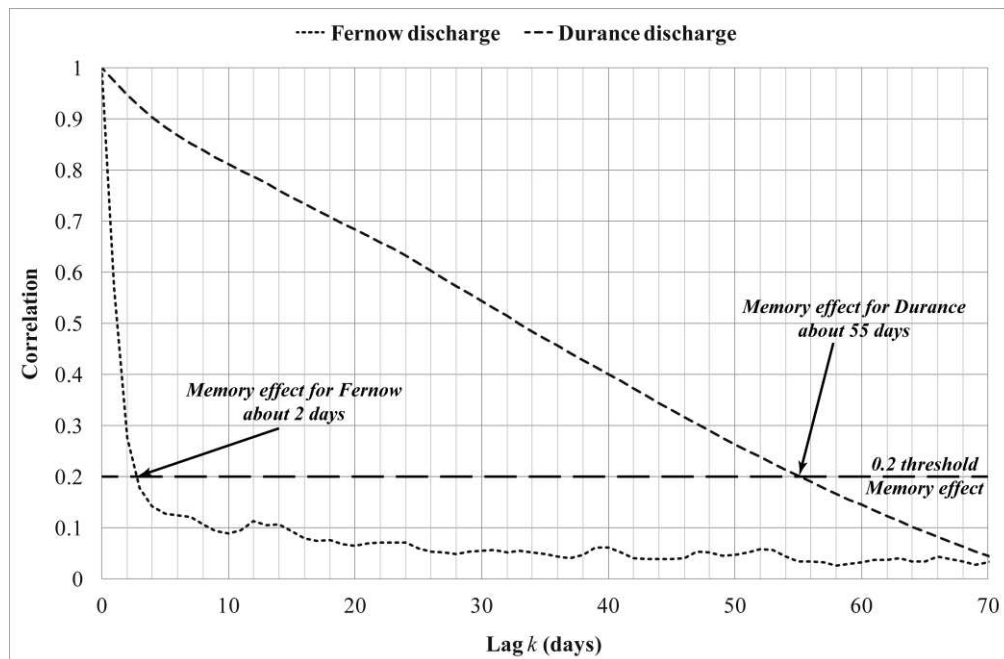
#### 4.2.2. Graphical analysis

Graphical representations of hydrographs and primary scores could help to understand how the model performs. For the workshop, many scores were calculated for each model, and they also were graphically represented by using a specific representation. In our study, we preferred to use a graphical representation of  $N_{SE}$  results, which allows different models to be easily compared. Bar graphs have been used to represent different levels of modelling. In all examples, the colour bar corresponds to the average result, which is bordered by a maximum and a minimum value. Results of bias are summarized in tables because of their very low variability. Results of bias for Fernow are also presented in bar plot because they are less affected than the  $N_{SE}$  by the time step which is not appropriated to model this catchment.

### 5. RESULTS

#### 5.1. Data analysis

Time-series analysis is generally used to better apprehend systems studied. In our research, this step allowed us to preselecting sliding time windows before to run cross-validation and to better understand the models obtained after the model selection stage. Discharge correlograms can provide information about the memory effect (time to reach 0.2 threshold) in a watershed (Mangin, 1984), which indicates the length of correlation of one discharge value with respect to the following values. As we can see in the correlogram in Fig.2, the Durance discharge is well correlated to itself (a memory effect of about 55 days), whereas the Fernow discharge is weakly correlated to itself (memory effect of about 2 days). This information will be further discussed in the results section. One can note that due to the small size of the Fernow catchment, the “apparent” memory effect of 2 days can be interpreted as the manifestation of the sampling theorem of Shannon (see 6.3).



**Fig. 2** Correlogram of discharge for both basins studied.

## 5.2. Durance

When applying level 3 of the protocol to the Durance watershed, there were many possibilities of combinations. Every input variable was briefly tested during this step. It has led to assimilate rainfall data because it was the most influential variable.

### 5.2.1. Non stationarity and observations on the Durance catchment

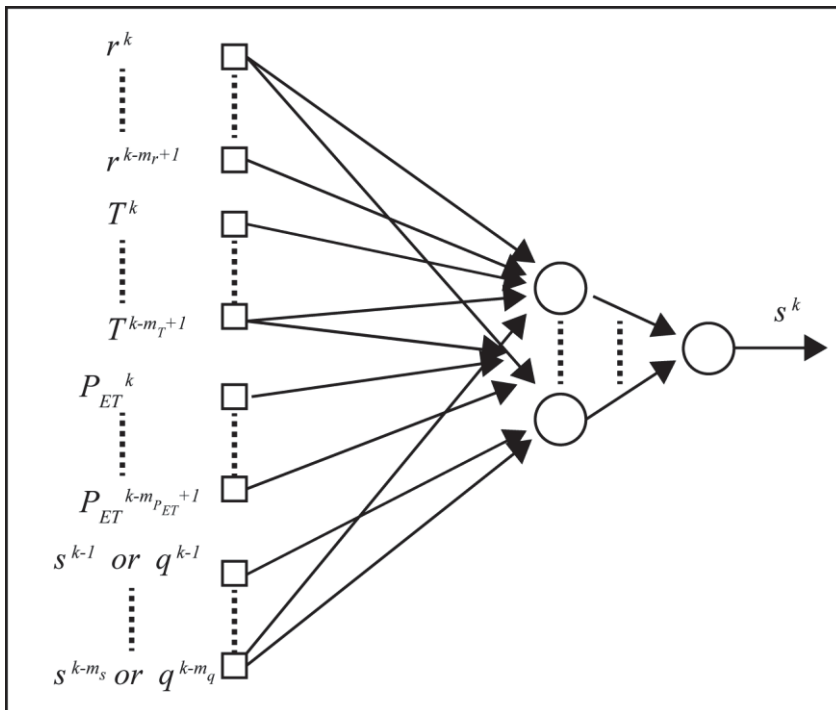
|  | Complete period  | $P_1$     | $P_2$  | $P_3$   | $P_4$     | $P_5$     |
|--|--|-----------|--|---|-----------|-----------|
| <b>Dates</b>                               | 1904-2010  | 1904-1924 | 1925-1945  | 1946-1966   | 1967-1987 | 1988-2008 |
| <b>Average discharge (m<sup>3</sup>/s)</b> | 52.9   | 54.6      | 54.5   | 53.8  | 53.4      | 48.1      |
| <b>Average temperature (°C)</b>            | 3.1  | 2.6       | 2.9  | 3.1   | 2.9       | 4.0       |
| <b>Cumulated precipitations (mm/year)</b>  | 1282   | 1295      | 1349   | 1261  | 1213      | 1238      |
| <b>Details on the period</b>               | Temperature increase implying a diminution of glaciers |           |  |   |           |           |
| <b>Discharge trend</b>                     |  |           | stable between $P_1$ & $P_2$                                 | decrease from $P_2$ to $P_5$  |           |           |
| <b>Hypothesis for discharge trend</b>      |  |           | temperature increase is compensated by higher precipitations | diminution of glaciers and snowpack decreases solid water resources for delayed discharge |           |           |

**Table 3** Details on all periods of the protocol for Durance catchment.

Table 3 contains information on each period. Information are obtained based on trends on average discharge and climatic variables. In addition, details on periods are given on the metadata of the workshop. Such information help to understand and underline the non stationarity.

### 5.2.2. Model architecture

The architecture evaluated was a standard multilayer perceptron represented in Fig.3. The exogenous variables chosen were: rainfall  $r^k$ , temperature  $T^k$ , and potential evapotranspiration  $P_{ET}^k$ . The state variable was the observed discharge  $q^k$  for the feed-forward model and the estimated discharge  $s^k$  for the recurrent model. Width of input windows (days) are detailed in Table 4.



**Fig. 3** Neural model for Durance simulation  $m_r$ ,  $m_T$ ,  $m_{PET}$ ,  $m_s$ ,  $m_q$  are respectively the temporal width of the variables  $r$  (rainfalls),  $T$  (temperature),  $P_{ET}$  (potential evapotranspiration),  $s$ ,  $q$

| Width of input windows (days)         |    |
|---------------------------------------|----|
| $r$                                   | 7  |
| $P_{ET}$                              | 4  |
| $T$                                   | 10 |
| $q / s$                               | 2  |
| Number of neurons in the hidden layer |    |
| 3                                     |    |


**Table 4** Architecture of Durance model.



### 5.2.3. $N_{SE}$ and bias

#### 5.2.3.1. Comparison of the models

Nash criteria for the Durance models are presented in Fig. 4.



**Fig. 4** Durance.  $N_{SE}$  values obtained for simulation during the full period and for the 5 training periods. Average  $N_{SE}$  for all test sets (colour bar), minimum and maximum (dashed lines) for all test periods, and for every level of modelling.

#### $N_{SE}$ for Levels 1 and 2

For Levels 1 and 2, one can observe that the feed-forward models always perform better than the recurrent models. This observation is consistent with what is generally described in the literature.

#### $N_{SE}$ for Level 3

Level 3 introduces data assimilation and adaptivity. One can observe that improvements in performance are marginal with adaptivity, and in some cases it actually decreases performance.

Data assimilation improves the feed-forward model marginally, whereas it significantly improves the recurrent model by about 60%.

#### Bias for all levels

The study of bias highlights the fact that neural network models have a very low bias (Table 5). Feed-forward models have a bias very close to 1 with the lowest standard deviation, while

recurrent models show higher standard deviation and bias, but are still very good. Neural models thus simulate very well the cumulative volume of water flowing in this watershed.

|                    | Feed-forward | Feed-forward adaptivity | Feed-forward assimilation | Recurrent | Recurrent adaptivity | Recurrent assimilation |
|--------------------|--------------|-------------------------|---------------------------|-----------|----------------------|------------------------|
| Mean               | 1.00         | 1.00                    | 0.99                      | 1.05      | 0.99                 | 1.02                   |
| Standard Deviation | 0.002        | 0.002                   | 0.004                     | 0.051     | 0.056                | 0.018                  |

**Table 5** Durance. Average bias for all training or test sets for all models for the Durance.

### 5.2.3.2. Comparison of models based on different training periods

#### Feed-forward models


The performance of the feed-forward models was globally homogeneous for the full training period and for all the training sub-sets. The feed-forward model is not truly sensitive to the training period.

#### Recurrent models

The recurrent models were more heterogeneous. As highlighted above, a recurrent model learns the actual system behaviour. We observed that when the calibration was done for the full period, as the test set was the same as the training set, performance was better. Moreover, performance improved for the calibration period from  $P_1$  to  $P_5$ .

### 5.2.3.3. Comparison of models on test sets

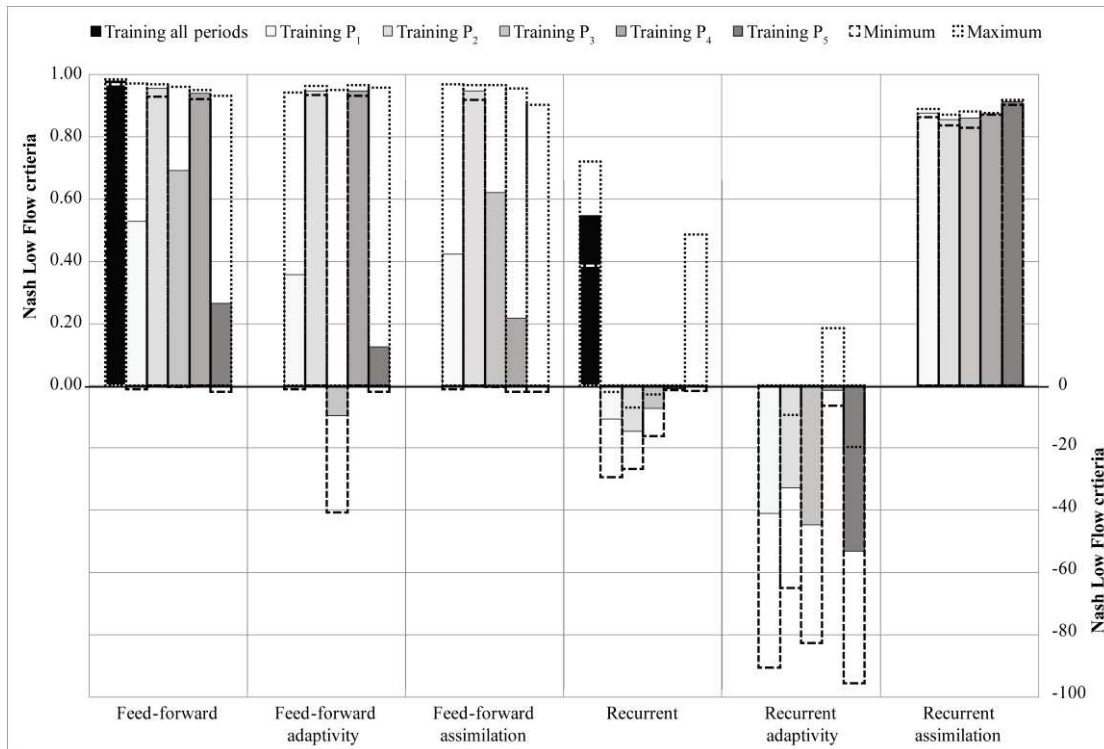
Nash criteria for the Durance models are presented in Fig. 5. In this figure, it is interesting to note that for all models there is the same scheme of performance as for the tests sets. Indeed, the best test set is  $P_4$ , next it is always  $P_1$ , and the worst is generally  $P_2$ . This is consistent with the hypothesis (Table 3) that during  $P_2$ , warming and decrease of glaciers is compensated by a strong cumulative precipitation.



**Fig. 5** Durance.  $N_{SE}$  values obtained for simulation for the entire period and for the 5 periods. Average  $N_{SE}$  for all training sets (colour bar), minimum and maximum (dashed lines) for all training periods, and for every level of modelling.

#### 5.2.4. $N_{SE}$ for low flows

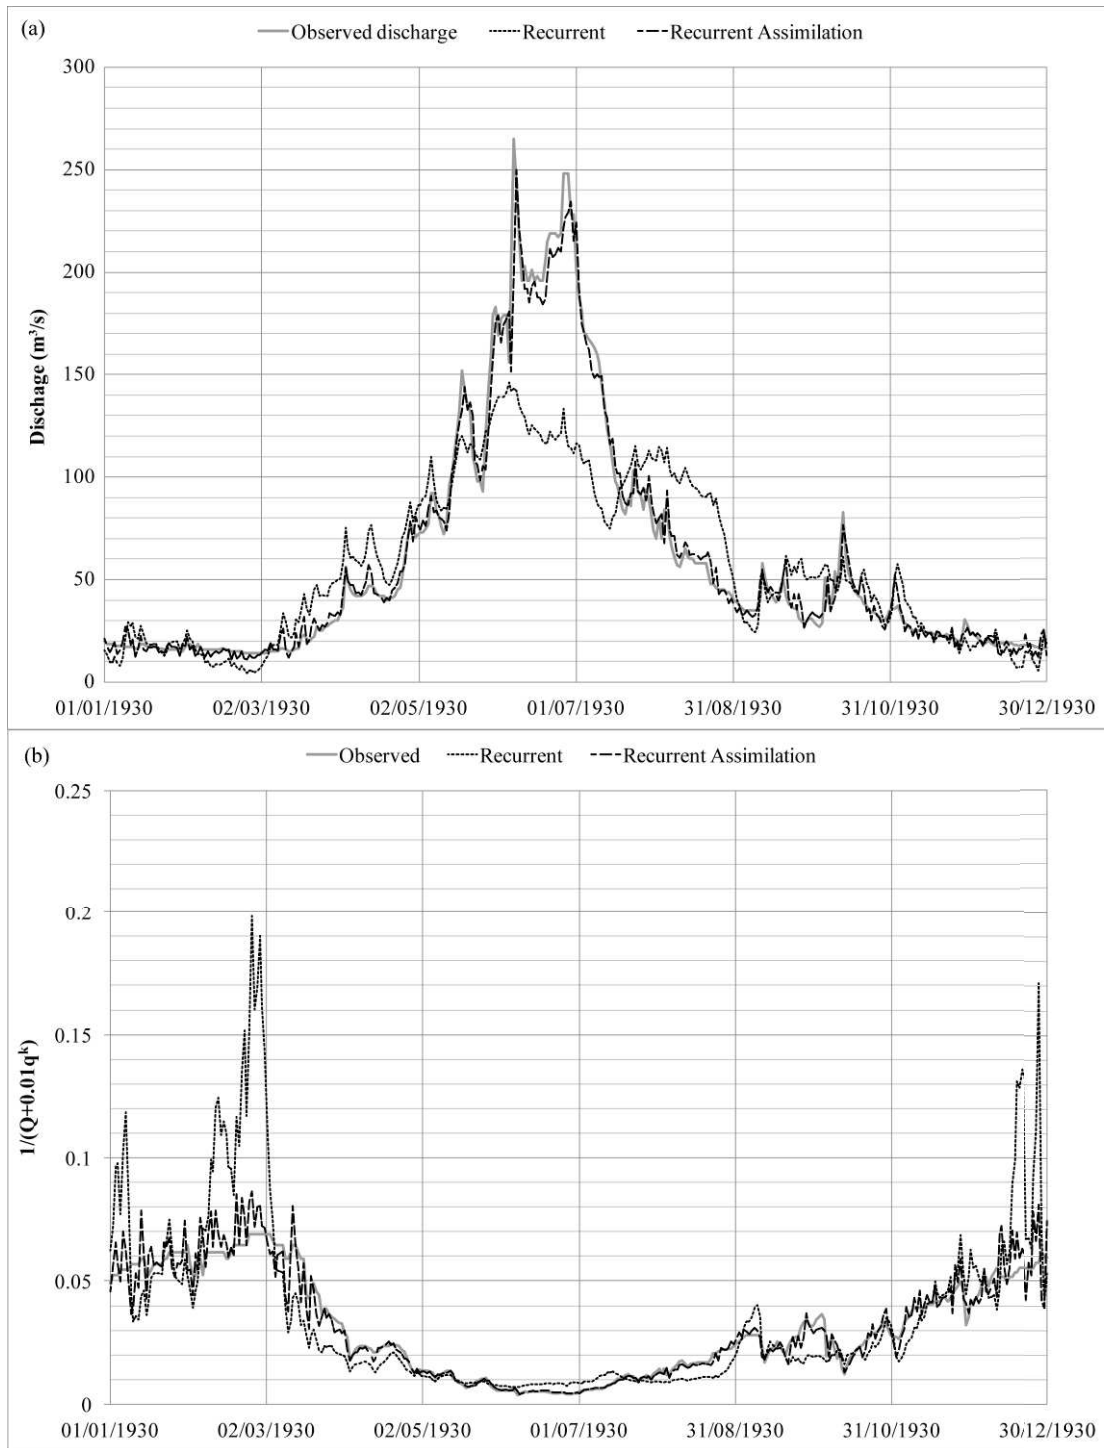
$N_{SE}$  can be used to estimate the performance of the model for low flows. Nash criteria are reported in Fig. 6. Results of  $N_{SE}$  for low flows show a high level of heterogeneity. It is important to note that the negative scale is one hundred times greater than the positive one. Therefore, every high negative value causes an important decrease in the average. In this case, it is interesting to look at extreme values to understand average values. The high range of negative values of  $N_{SE}$  for low flows in this basin seems to be linked to the following points. First, we can see in Table 6 that the gap between 0 and the minimum value of discharge is relatively high, especially for calculating  $N_{SE}$  for low flows. Neural models are not limited to a range of observed values, and could therefore return a value of zero. Next, we observed high variability in the observed discharge, which gives more weight to lower values for computing  $N_{SE}$  for low flows (Fig. 7).



**Fig. 6** Durance.  $N_{SELowFlows}$  values obtained for simulation for the full period and for the 5 periods. Average  $N_{SELowFlows}$  for all test sets (colour bar), minimum and maximum (dashed lines) for all test periods and for every level of modelling. In this figure, there are two different scales, one for positive values from 0 to 1, and one for negative values from 0 to -100.

|                                       | Min | Max   | Average |
|---------------------------------------|-----|-------|---------|
| Discharge ( $m^3/s$ ) for full period | 5.7 | 489.6 | 52.9    |

**Table 6** Statistics of the observed values of discharge of the Durance at La Clapière.



**Fig. 7** Durance: illustration of performances improvement for recurrent model using data assimilation for a year of  $P_2$  (test) and for training with  $P_3$ . (a) Discharge; (b) modified discharge for  $N_{SELowFlow}$  computation (with  $Q$  the discharge observed or simulated and  $q^k$  average of observed discharge).

#### 5.2.4.1. Comparison of models

In Fig. 6,  $N_{SE}$  values for low flows in the feed-forward model are very heterogeneous. In all cases, bad performance is due to only one negative value, other values are nearly 0.9. Because the distribution is heterogeneous, the median of the Nash criteria would provide more

representative values. One can see that the feed-forward model presents generally good performance.

Adaptivity and data assimilation tend to degrade the performance of the feed-forward model for low flows. Regarding the recurrent model, performance is generally poor, and adaptivity makes results worse. On the contrary, data assimilation really improves  $N_{SE}$  for low flows with the recurrent model. It also stabilizes results as we can see in terms of the low variability. The feed-forward model is thus better than the recurrent model except for the recurrent model with data assimilation.

#### 5.2.4.2. Comparison of training periods

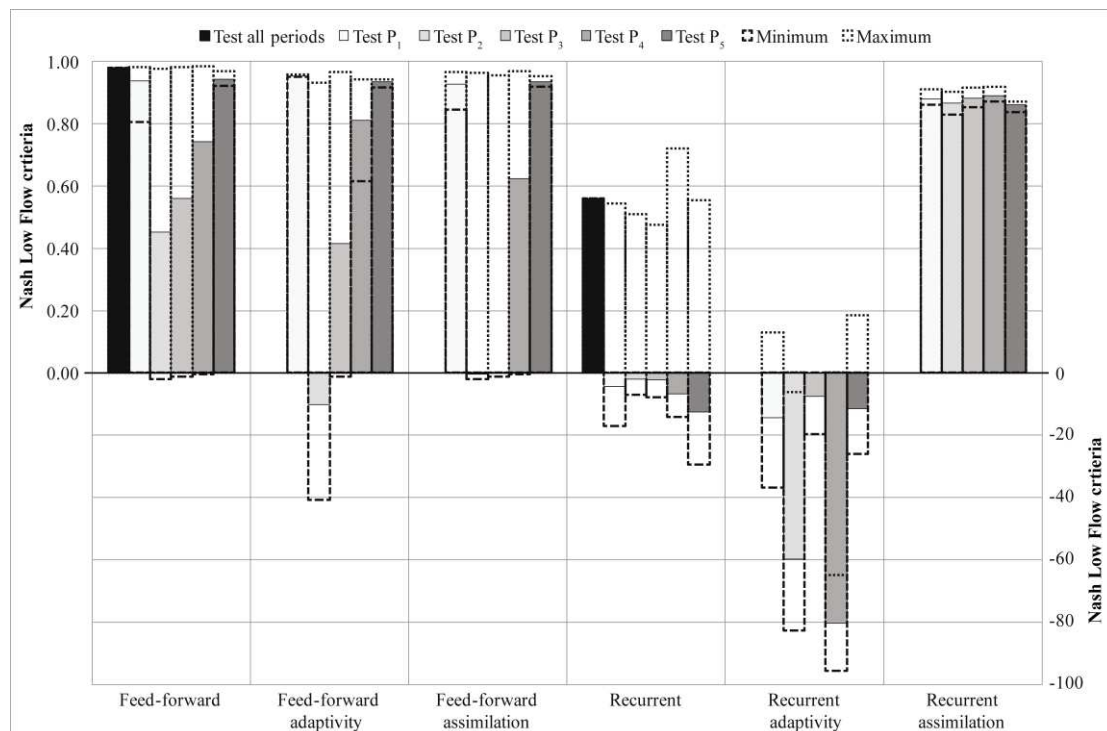
In the study of  $N_{SE}$  for low flows, best performance is obtained with calibration for the full period for level 1 in the protocol, which is not surprising because the test period is the same as the training period.

The feed-forward model with and without adaptivity produces good results for training for the  $P_2$  and  $P_4$  periods. It is difficult to identify “schemes” of improvement with other models.

#### 5.2.4.3. Comparison of test periods

The results presented in Fig. 8 are generally heterogeneous with good maxima for the feed-forward model and worse results for the recurrent one, except when there is data assimilation. The feed-forward models all show the same trend with better results for testing periods  $P_1$  and  $P_5$ . Moreover, results tend to improve from  $P_2$  to  $P_4$ .

No trend could be identified in the tests using recurrent models.



**Fig. 8** Durance.  $N_{\text{SELowFlows}}$  values obtained for simulation for the full period and for the 5 periods. Average  $N_{\text{SELowFlows}}$  for all training sets (colour bar), minimum and maximum (dashed lines) for all training periods, and for every level of modelling. In this figure, there are two different scales, one for positive values from 0 to 1, and the other for negative values from 0 to -100.

### 5.3. Fernow

First of all, in Fig. 2 one can examine the correlogram obtained for Fernow discharge. It indicates that the memory effect is equal to 2 days, (*i.e.*, 2 sampling periods). This value shows a consequence of under-sampling the Fernow discharge time series. Indeed, according to the *Shannon-Nyquist* theorem, a signal of  $T$  smallest period must be sampled at least at  $T/2$ . Consequently, sampling at a 1 day interval implies we cannot visualise phenomena for which the time response is less than 2 days. Since the Fernow catchment is very small ( $0.2 \text{ km}^2$ ), and was sampled at one day intervals, short phenomena, with a response time of less than 2 days, are not represented.

For the Fernow watershed, all exogenous variables (temperature, rainfall) were assimilated.

#### 5.3.1. Non stationarity and observations on the Fernow catchment

|  | Complete period | $P_1$   | $P_2$   | $P_3$   | $P_4$     | $P_5$     |
|--|-----------------|---|---|---|-----------|-----------|
| <b>Dates</b>                               | 1959–2009       | 1959–1968   | 1969–1978   | 1979–1988   | 1989–1998 | 1999–2008 |
| <b>Average discharge (m<sup>3</sup>/s)</b> | 3.74E-03        | 3.65E-03  | 4.69E-03  | 4.61E-03  | 3.45E-03  | 2.41E-03  |
| <b>Average temperature (°C)</b>            | 8.2             | 8.8   | 9.0   | 9.2   | 7.8       | 6.0       |
| <b>Cumulated precipitations (mm/year)</b>  | 1454            | 1364  | 1415  | 1458  | 1483      | 1406      |
| <b>Details on the period</b>               |                 | <ul style="list-style-type: none"> <li>☐ forest cut of the lower part of the basin (Mar - Oct 1964)</li> <li>☐ forest cut of the upper part of the basin (Oct 1967 - Feb 1968)</li> </ul> | <ul style="list-style-type: none"> <li>☐ plantation of firtrees (Mar - Apr 1973)</li> </ul> |   |           |           |
| <b>Discharge trend</b>                     |                 |   | increase from $P_1$ to $P_2$  | decrease from $P_2$ to $P_5$  |           |           |
| <b>Hypothesis for discharge trend</b>      |                 |   | lack of trees decreases water needs in the watershed and increases runoff                   | vegetation growth increases water needs, water retention and decreases runoff |           |           |

**Table 7** Details on all periods of the protocol for Fernow catchment.

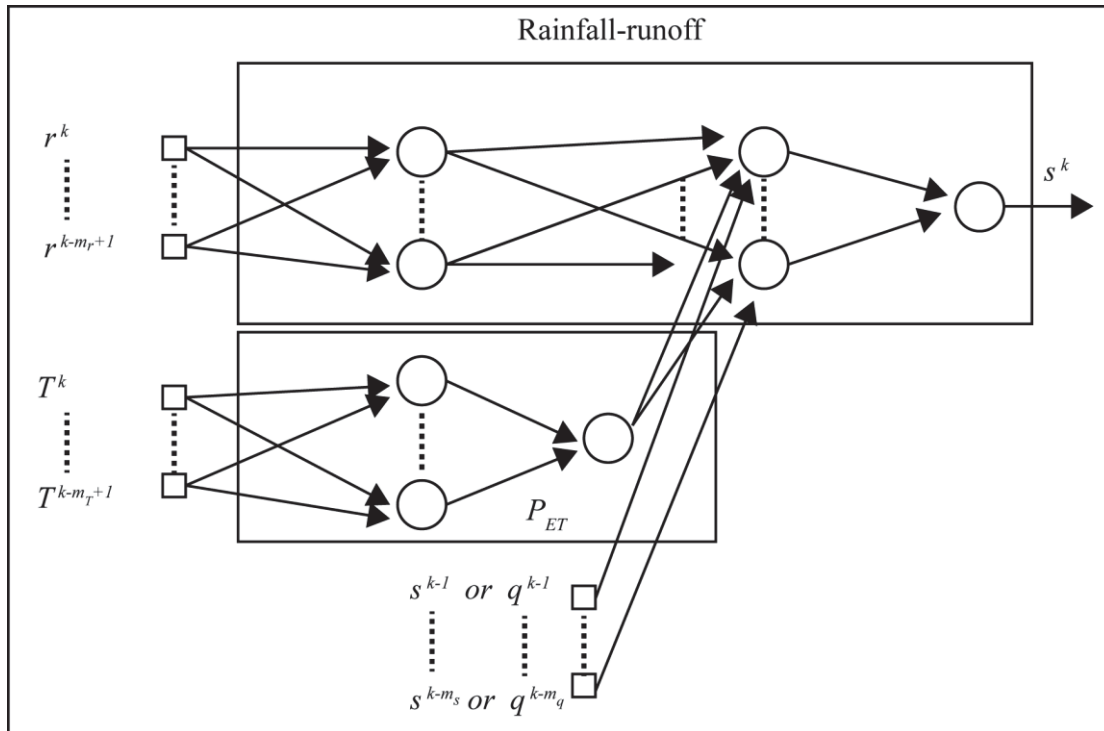
As Table 3, Table 7, contains different kind of information and hypothesis on each periods.

### 5.3.2. Model architecture

When designing a continuous hydrological model with snowmelt, it is necessary to take account of temperature. Nevertheless the first trials for the Fernow basin showed that better results of simulation were given using a simple mean annual description of  $P_{ET}$  variations during the year. This observation was highlighted by Oudin *et al.* (2005) for reservoir models, and it is also applicable to neural network models which do not require very accurate  $P_{ET}$  information, and only a typical annual-based variation. In this spirit, and in order to force the model to create its own estimation of effect of temperature, we built a model with a specific architecture, based on Johannet (2008). Two branches were thus designed in the neural model: one for the rainfall-runoff relation, and the other for the influence of *temperature*, or  $P_{ET}$ . This model is shown in Fig. 9 and details on the width of input windows and on the order of the



model are shown in Table 8. It was applied to both recurrent and feed-forward models. Preliminary tests proved that this estimation of  $P_{ET}$  was slightly more effective than the one provided in the dataset. This refinement was not applied to the Durance model which was very good with the standard architecture.



**Fig. 9** Neural model for Fernow simulation  $m_r$ ,  $m_T$ ,  $m_s$ ,  $m_q$  are respectively the temporal width of the variables  $r$  (rainfalls),  $T$  (temperature),  $s$ ,  $q$ .

|         | Rainfall-runoff branch                                  | $P_{ET}$ branch   |
|---------|---|---|
|         | Width of input windows (days)<br>Feed-forward/recurrent | Width of input windows (days)<br>Feed-forward/recurrent |
| $r$     | 4 / 4   | 4 / 4   |
| $T$     | -   | 4 / 6   |
| $q / s$ | 3 / 3   | -   |
|         | Number of neurons in the hidden<br>layer                | Number of neurons in the hidden<br>layer                |
|         | 5 / 4   | 4 / 4   |

**Table 8** Architecture of Fernow model.

### 5.3.2.1. Comparison of the models

#### Bias for all levels

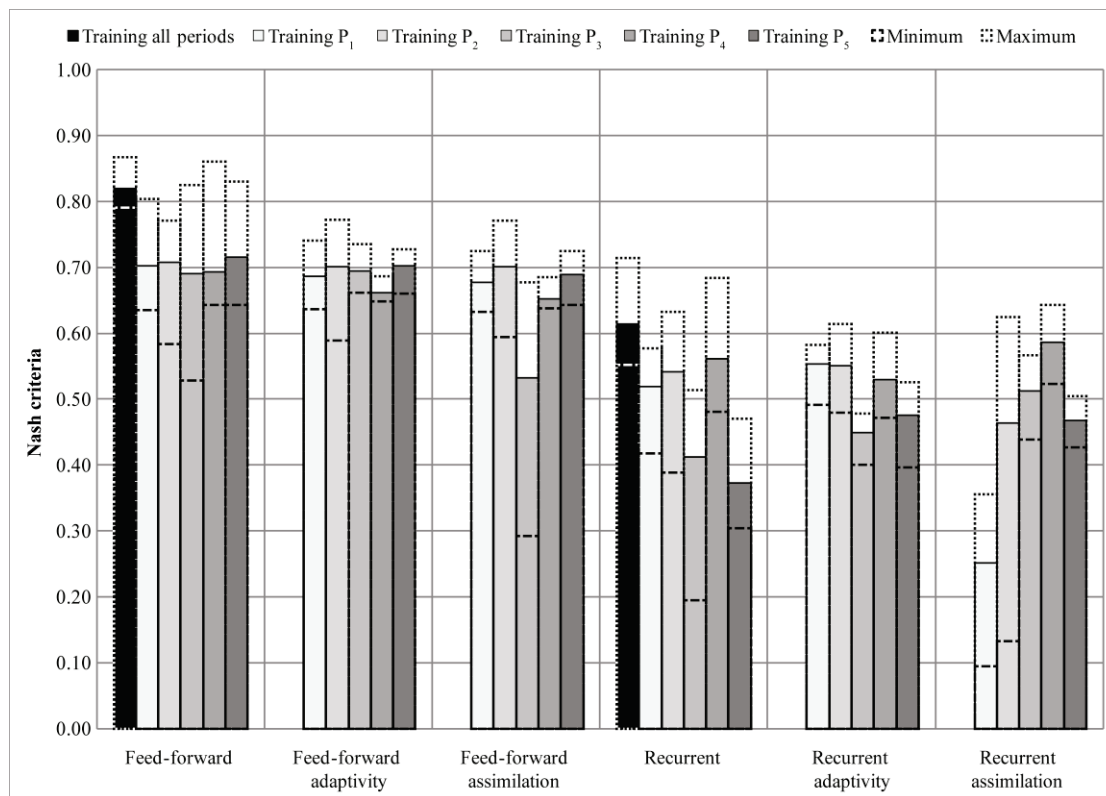
For the Fernow watershed, model bias remains low (Table 9). For all models, bias is close to 1, but the standard deviation of bias for recurrent models is higher than for the feed-forward models. Neural models thus provide good estimates of the flow volume in this basin.

|                    | Feed-forward | Feed-forward adaptivity | Feed-forward assimilation | Recurrent | Recurrent adaptivity | Recurrent assimilation |
|--------------------|--------------|-------------------------|---------------------------|-----------|----------------------|------------------------|
| Mean               | 1.04         | 1.03                    | 1.01                      | 0.98      | 1.07                 | 1.18                   |
| Standard Deviation | 0.103        | 0.044                   | 0.102                     | 0.285     | 0.070                | 0.362                  |

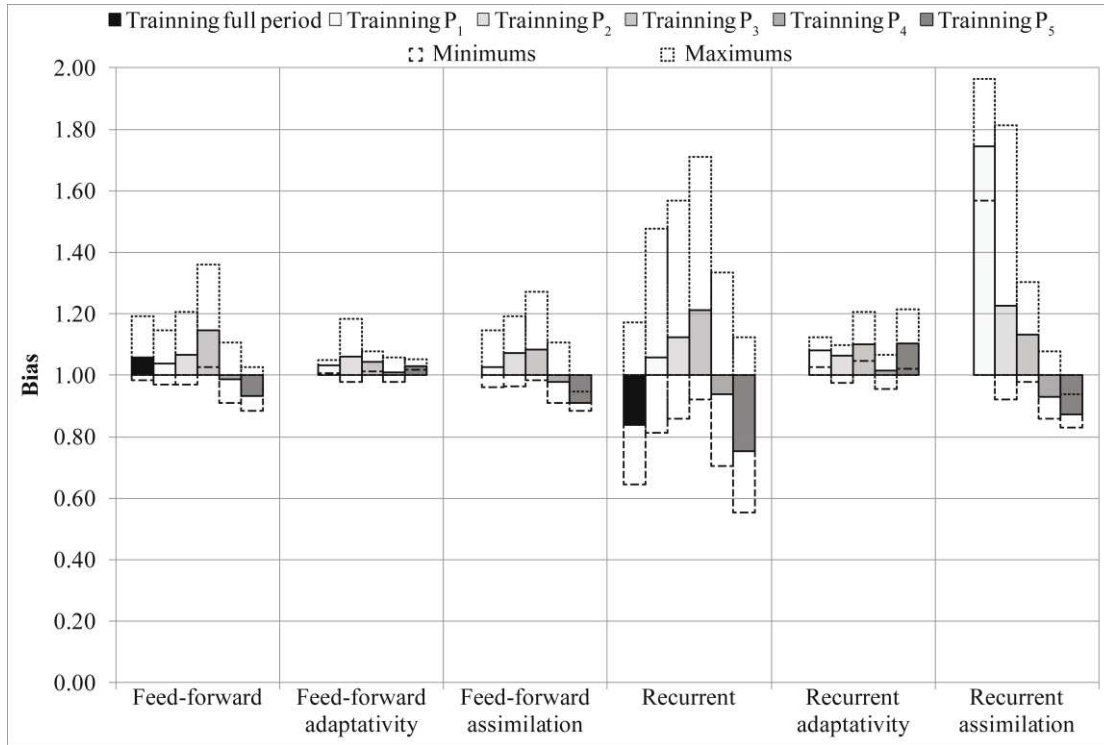
**Table 9** Average bias for all training and testing periods for all models used for the Fernow.

### $N_{SE}$ and bias for Levels 1 and 2

Fig. 10 and Fig. 11 show that the feed-forward model performs much better (higher  $N_{SE}$  and bias closer to 1) than the recurrent model. Nash criteria and bias of Fernow small experimental basin models are presented in Fig. 10 and Fig. 11.



**Fig. 10** Fernow.  $N_{SE}$  values obtained for simulation on the full period and for the 5 periods. Average  $N_{SE}$  for all test sets (colour bar), minimum and maximum (dashed lines) for all test periods, and for every level of modelling.



**Fig. 11** Fernow. Bias values obtained for simulation on the full period and for the 5 periods. Average bias for all test sets (colour bar), minimum and maximum (dashed lines) for all test periods, and for every level of modelling.

### **$N_{SE}$ and bias for Level 3**

Methods used for level 3 of the protocol (adaptivity and data assimilation) are not really effective for improving  $N_{SE}$  performances for this basin.

In all of cases in which adaptivity is used, the gap between the maximum and the minimum values decreases. This means that adaptivity decreases the variability of model results. On the contrary, data assimilation tends to increase this variability of results. Adaptivity also reduces variability of bias values, which means that this method improves the estimation of the flow volume in the basin.

#### **5.3.2.2. Comparison of training periods**


As already observed, for both the recurrent and the feed-forward models, average performance was better for the full training period (Fig. 10). This behaviour is not surprising. But, for the flow volume, we can see in Fig. 11 that when the training is done with the period  $P_4$ , we have better results.

#### **5.3.2.3. Comparison of test periods**

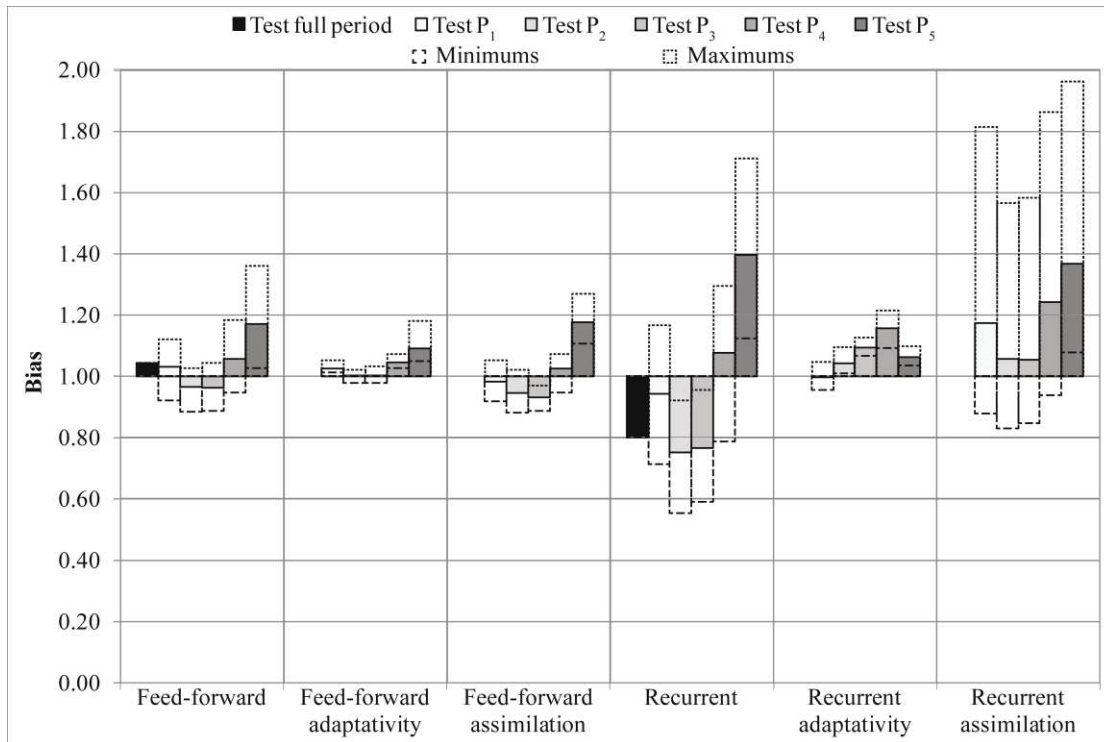
Nash criteria and bias for the small experimental Fernow basin models are presented in Fig. 12 and Fig. 13. In Fig. 12, the feed-forward model for levels 1 to 3 of the protocol shows the same trend in results between the different tests sets, ranging from best to worst as follows:  $P_4, P_3, P_1, P_2, P_5$ .

Bias of the feed-forward models (Fig. 13) show that the flow volume is well represented for  $P_1$  to  $P_3$ . It is probably due to growth of vegetation, which increases its water needs and retention during  $P_4$  and  $P_5$ .

For the recurrent model, no real trend was observed, except for the testing period  $P_5$ , which was the hardest period to model. Nevertheless, in level 3, adaptivity provides better  $N_{SE}$  scores than data assimilation. This is consistent with the type of non-stationarity linked to the basin itself.



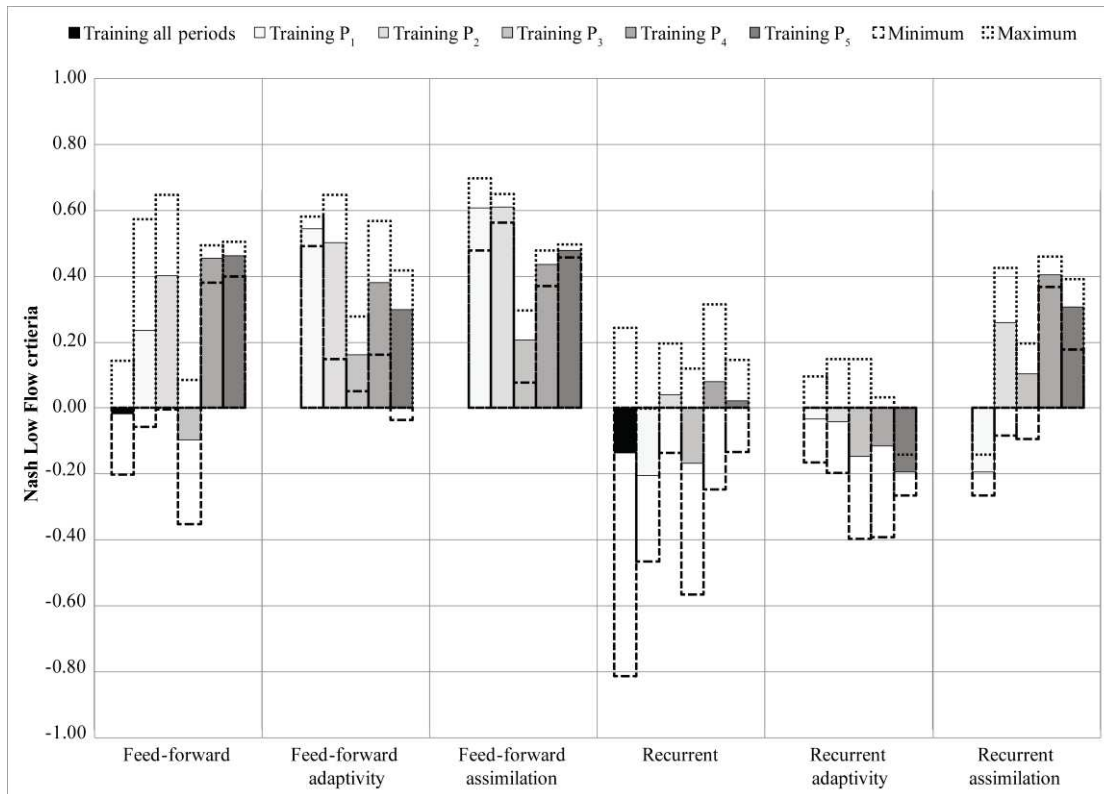
**Fig. 12** Fernow.  $N_{SE}$  values obtained for simulation for the full period and for the 5 periods. Average  $N_{SE}$  for all training sets (colour bar), minimum and maximum (dashed lines) for all training periods, and for every level of modelling.




**Fig. 13** Fernow. Bias values obtained for simulation for the full period and for the 5 periods. Average bias for all training sets (colour bar), minimum and maximum (dashed lines) for all training periods, and for every level of modelling.

### 5.3.2. $N_{SE}$ for low flows

As observed for the Durance watershed,  $N_{SE}$  for low flows are heterogeneous, and may take negative values (Fig. 14), but for the Fernow watershed, negative values of  $N_{SE}$  remain in the same range as the positive values. This is probably due to the low range of observed discharge values (Fig. 15), which are presented in Table 10.



**Fig. 14** Fernow.  $N_{SELowFlows}$  values obtained for simulation for the full period and for the 5 periods. Average  $N_{SELowFlows}$  for all test sets (colour bar), minimum and maximum (dashed lines) for all test periods, and for every level of modelling.



**Fig. 15**

Fernow: Illustration of performances improvement for feed-forward model using adaptivity for a year of  $P_3$  (test) and for training with  $P_5$ . (a) Discharge; (b) modified discharge for  $N_{SELowFlow}$  computation (with  $Q$  the discharge observed or simulated and  $q^k$  average of observed discharge).

|   | Min | Max   | Mean  |
|---|-----|-------|-------|
| Discharge (m <sup>3</sup> /s) for full period | 0   | 0.186 | 0.004 |

**Table 10** Statistics of observed values of discharge for the Fernow basin. Comparison of models

Fig.14 shows that, as usual, the feed-forward model is more effective than the recurrent model for modelling low flows (except for the recurrent model with data assimilation).

In some cases, the adaptive method improves  $N_{SE}$  for low flows, whereas it could negatively affect model performance in other cases. Data assimilation clearly improves the performance of both models. It seems that behaviour regarding low flow is the opposite of the one regarding high flows.


**5.3.2.1. Comparison of training periods**

The feed-forward model (Fig. 14) does not accurately represent the low flow period when the training is done with the  $P_3$  sub-set, which is also true for the full period. This means that there is  $P_3$  dataset-specific behaviour, which can be trained (good performance when test is done on the training subset for the database or for  $P_3$  alone). Nevertheless, models trained with dataset including the  $P_3$  set are unable to generalize for low flow values. This could be explained because the  $P_3$  period is specific in terms of the signals: it contains less summer droughts, as was the case at the beginning or the end of the full period.

No trend associated with the training periods could be identified.

**5.3.2.2. Comparison of test periods**

For all levels of modelling, Fig. 16 shows that period  $P_3$ , which had the worst results in terms of training, displays the best performance for testing.





**Fig. 16** Fernow.  $N_{\text{SELowFlows}}$  values obtained for simulation for the full period and for the 5 periods. Average  $N_{\text{SELowFlows}}$  for all training sets (colour bar), minimum and maximum (dashed lines) for all training periods, and for every level of modelling.

## DISCUSSION

### 5.4. Durance watershed

The application of three levels of the protocol reveals that discharge in the Durance can be accurately simulated ( $N_{\text{SE}} > 0.9$ ;  $N_{\text{SELowFlows}} > 0.8$ ;  $\text{bias} \approx 1$ ) by using artificial neural network models, in non-stationary conditions. The best results for the 3 criteria ( $N_{\text{SE}}$ ,  $N_{\text{SELowFlows}}$ , and bias) were obtained with the feed-forward model and with the recurrent model with data assimilation on “high flows”. In this case, one can see that data assimilation applied to the recurrent model improves performance significantly (about 60% for  $N_{\text{SE}}$ , and from about -20 to 0.8 for  $N_{\text{SELowFlows}}$ ). Moreover, data assimilation tends to stabilize the model, which means that the gap between the scores obtained with different calibrating and testing periods decreases. This is coherent with the initial assumption stating that non-stationarity was caused by climate change (input variables of the models).

In this workshop, level 1 and level 2 of the protocol enabled us to evaluate how sensitive the model is to non-stationary conditions. Actually, level 1 consists in calibrating the model for the full period, which contains all the examples. On the other hand, level 2 consists in calibrating the model for each sub-period ( $P_1$ ,  $P_2$ ,  $P_3$ ,  $P_4$ , and  $P_5$ ). One can see without surprise that when the test was performed on the calibration period, the scores were slightly better. We also observed that the gap between different periods (for calibration and testing) is very small. Considering that neural network models entail statistical training, one can conclude that the behaviour of the watershed was not modified between the different periods. This means that non-stationarity is due to the modification of the inputs, as confirmed by metadata (improvement of temperature).

Compared to studies presented during the workshop (*Thirel and Andréassian (2013). Introduction and synthesis of the experiments made by the workshop participants, <http://non-stationarities.irstea.fr/the-workshop/>, last consultation Nov. 2013*), Table 11 underlines that ANN Durance models are well working. In addition, the low sensitivity to calibration and validation periods means that ANN models performed good interpolation as well as good “extrapolation” to other situations in the state space.

|                  | Model                     | $N_{SE}$       |
|------------------|---------------------------|----------------|
| Workshop session | Feed-forward              | [0.93 ; 0.98]  |
|                  | Recurrent                 | [0.5 ; 0.97]   |
|                  | AWBM <sup>(1)</sup>       | [-0.29 ; 0.1]  |
|                  | GR4J <sup>(1)</sup>       | [-0.3 ; -0.7]  |
|                  | IHACRES <sup>(1)</sup>    | [-0.14 ; 0.26] |
|                  | Sacramento <sup>(1)</sup> | [-1.9 ; -1.54] |
|                  | Simhyd <sup>(1)</sup>     | [-0.32 ; 0.08] |
|                  | SMARG <sup>(1)</sup>      | [-0.02 ; 0.11] |
| Other studies    | E-HYPE <sup>(2)</sup>     | 0.55 ; 0.67    |
|                  | LSM <sup>(3)</sup>        | ≈0.9           |
|                  | SIM <sup>(4)</sup>        | ≈0.9           |

**Table 11** Comparison of Nash criteria for Durance catchment from different model: (1) Vaze et al. 2013, (2) Lindström and Donnelly 2013, (3) Magrand et al. 2010, (4) Lafaysse et al. 2011.

### 5.5. Fernow watershed 6

Application of the protocol to this watershed revealed that discharge could be reasonably well simulated ( $N_{SE} > 0.7$ ) using neural network models. Performance was slightly better for the feed-forward model for  $N_{SE}$  and bias. One also noticed that application of adaptivity provides better models. Meanwhile, data assimilation improved  $N_{SE}$  slightly for low flows for both models. In addition, applying adaptivity tends to decrease the gap between results obtained with different periods of training and testing, which means that this method stabilizes the model.

Without surprise, level 1 of the protocol is the most effective for modelling this system. This offers proof once again that testing on the same set as that used for the training provides the best score. Moreover, there was a high degree of heterogeneity according to the calibration period. These results highlight the fact that each period corresponds to specific behaviour of the watershed, the relationship does not remain the same due to important modifications that occur in the basin (forest cut, and new trees planted in the basin). As indicated above, a neural network model learns relationships between inputs and outputs. But in the case of the Fernow basin, the relation doesn't stay the same for the watershed as well as in the model continuously modified by adaptivity.

Nevertheless, Table 12 shows that results of the recurrent model are close to other results presented during the workshop (*Thirel and Andréassian (2013). Introduction and synthesis of the experiments made by the workshop participants, <http://non-stationarities.irstea.fr/the-workshop/>, last consultation Nov. 2013*), whereas the feed-forward model provides better results.

|                         | <b>Model</b>        | $N_{SE}$  |
|-------------------------|---------------------|-----------|
| <b>Workshop session</b> | <b>Feed-forward</b> | 0.68±0.08 |
|                         | <b>Recurrent</b>    | 0.48±0.12 |
|                         | AWBM [*]            | 0.43±0.11 |
|                         | SimHyd [*]          | 0.40±0.12 |

**Table 12** Comparison of Nash criteria for Fernow catchment from different model: Yu and Zhu 2013.

## 6. CONCLUSION

The IAHS workshop in Göteborg (July 2013) enabled to evaluate the ability of neural network models to investigate non-stationary modelling in two different basins. The first basin (Durance) was large and subject to climate change, while the second (Fernow) was very small and subject to land cover modifications. As neural models were known for their intrinsic ability to take real time signals into account, this was the opportunity to compare the classical neural network modelling and other methods specifically designed for changing catchments (adaptivity) or environmental changes (data assimilation). For each of the three configurations, two types of models (recurrent and feed-forward) were investigated. Both watersheds were well represented by the six types of models designed, which highlights once again the generic nature of neural modelling. In addition, our examination of the results synthesized using Nash criteria offers proof that modelling was consistent with the primary assumption: adaptivity method works better for non-stationary catchments, while data-assimilation corrects variables subject to climate change better. Finally, from the point of view of effectiveness, the feed-forward model fed by previously observed discharge generally surpasses the other two techniques: data assimilation and adaptivity. We found few configurations for which the recurrent model, improved by data assimilation, was marginally better than the feed-forward model.

This study, which is based on input-output relation, underlines that ANN models provide good results in changing conditions. The feed-forward model, which depends on state measurement (discharge), is better for forecasting and modelling. The recurrent model, improved by data assimilation or adaptivity, which better represents the dynamic of the process, should be particularly suitable for flash flood forecasting.

## 7. ACKNOWLEDGEMENTS

The authors would like to thank G. Thirel and V. Andréassian for the availability of data and the interesting initiative of the IAHS workshop. The constant efforts made by Dominique Bertin (with the Geonosis Company) to enhance and develop the neural network software RNFPro are hereby acknowledged as well. Last but not least, special thanks go to the French National Research Agency for supporting the FLASH project (ANR-09-SYSC 004), which has contributed to the development of data assimilation in neural formalism.

## REFERENCES

Artigue, G., Johannet, A., Borrell, V., Pistre, S., 2012. Flash flood forecasting in poorly gauged basins using neural networks: case study of the Gardon de Mialet basin (southern France). *Natural Hazards and Earth System Sciences*, 12, 3307-3324.

- Barron, A.R., 1993, Universal Approximation Bounds for Superpositions of a Sigmoidal Function. *IEEE Transactions on Information Theory*, 39, 930-945.
- Bornancin-Plantier A., 2013. Conception de modèles de prévision des crues éclair par apprentissage artificiel. *Thèse de doctorat de l'Université Pierre et Marie Curie (Paris 6)*.
- Bowden, G.J., Maier, H.R., Dandy, G.C., 2002. Optimal division of data for neural network models in water resources applications. *Water Resources Research*, 38(2), 1010-1021.
- Coulibaly P., Baldwin C.K., 2008. Dynamic Neural Networks for Non-stationary Hydrological Time Series Modeling. *Practical Hydro-informatics. Water Science and Technology Library*, 68, 71-85.
- Coulibaly, P., Anctil, F., Bobée, B., 1999. Hydrological forecasting using artificial neural networks: The state of the art. *Can. J. Civ. Engng.* 26(3), 293–304.
- Coulibaly, P., Anctil, F., Rasmussen, P.F., Bobée, B., 2000. A recurrent neural networks approach using indices of low-frequency climatic variability to forecast regional annual runoff. *Hydrol. Processes*, 14(15), 2755–2777.
- Coulibaly, P., Baldwin, C.K., 2005. Nonstationary hydrological time series forecasting using nonlinear dynamic methods. *Journal of Hydrology*, 307 (1–4), 164–174.
- Dreyfus, G. (2005). *Neural Networks: Methodology and Applications*. Springer.
- Edwards, P. J., Wood, F., (1994). Centroid lag time changes resulting from harvesting, herbiciding, and stand conversion. *Effects of human-induced changes on hydrologic systems Symposium*. American Water Resources association, 727-734.
- Geman, S., Bienenstock, E., Doursat, R., 1992. Neural networks and the bias/variance dilemma. *Neural Computation*, 4(1), 1–58.
- Hagan, M.T., Menhaj, M.B., 1994. Training feedforward networks with the Marquardt algorithm. *Neural Networks, IEEE Transactions on Neural Networks*, 5(6), 989-993.
- Haykin, S., 1999. *Neural Networks: A Comprehensive Foundation*. Prentice-Hall, Upper Saddle River, N.J.
- Haykin, S., Li, L., 1995. Nonlinear adaptive forecasting of non-stationary signals. *IEEE Transaction on Signal Processing*, 43(2), 526–535.
- Hornik, K., Stinchcombe, M., White, H., 1989. Multilayer feedforward networks are universal approximators. *Neural Networks 2*, 359-366.
- Johannet, A., Vayssade, B., Bertin, D., 2008. Neural Networks: From Black Box Towards Transparent Box. Application to Evapotranspiration Modeling. *International Journal of Computational Intelligence*, 4(3), 163-170
- Kong-A-Siou, L., Johannet, A., Borell-Estupina, V., Pistre, S., 2011. Complexity selection of a neural network model for karst flood forecasting: The case of the Lez basin (southern France). *Journal of Hydrology*, 403, 367–380.
- Kong-A-Siou, L., Johannet, A., Borell-Estupina, V., Pistre, S., 2012. Optimization of the generalization capability for rainfall-runoff modeling by neural networks: The case of the Lez aquifer (southern France). *Environmental Earth Sciences*, 65 (8), 2365-2375.
- Kong-A-Siou, L., Cros, K., Johannet, A., Borell-Estupina, V., Pistre, S., 2013. KnoX method, or Knowledge eXtraction from neural network model. Case study on the Lez karst aquifer (southern France). *Journal of Hydrology*, 507, 19-32.
- Lafaysse, M., Hingray, B., Etchevers, P., Martin, E., Obled, C., 2011. Influence of spatial discretization, underground water storage and glacier melt on a physically-based hydrological model of the Upper Durance River basin. *Journal of Hydrology*, 403(1–2), 116-129.
- Le Dimet, F. X., Talagrand, O. 1986. Variational algorithms for analysis and assimilation of meteorological observations: Theoretical aspects. *Tellus*, 38A, 97–110.

- Lindström, G., Donnelly, C. 2013. HYPE model simulations for non-stationary conditions in European medium sized catchments. Workshop-IAHS.
- Maier, H.R., Dandy, G.C., 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling and Software*, 15(1), 101-124.
- Magand, C., Ducharne, A., Le Moine, N., (2013). Sensitivity of a physically-based LSM to the calibration period in the Upper Durance catchment. Workshop-IAHS.
- Mangin, A. 1984. Pour une meilleure connaissance des systèmes hydrologiques à partir des analyses corrélatoire et spectrale. *Journal of Hydrology* 67(1-4), 25-43.
- Nash, J. E., Sutcliffe, J. V., 1970. River flow forecasting through conceptual models part I - A discussion of principles. *Journal of Hydrology*, 10(3), 282-290.
- Nerrand, O., Roussel-Ragot, P., Personnaz, L., Dreyfus, G., Marcos, S., 1993. Neural networks and nonlinear adaptive filtering: Unifying concepts and new algorithms. *Neural Computation*, 5(2), 165-199.
- Oudin, L., Hervieu, F., Michel, C., Perrin, C., Andréassian, V., Anctil, F., Loumagne, C., 2005. Which potential evapotranspiration input for a lumped rainfall-runoff model? Part 2—Towards a simple and efficient potential evapotranspiration model for rainfall-runoff modelling. *Journal of Hydrology*, 303, 290–306
- Pereira Filho, A.J., Dos Santos, C.C., (2006). Modeling a densely urbanized watershed with an artificial neural network, weather radar and telemetric data. *Journal of Hydrology* 317, Issues 1-2, 31-48.
- Pushpalatha, R., Perrin, C., Le Moine, N., Andréassian, V., 2012. A review of efficiency criteria suitable for evaluating low-flow simulations. *Journal of Hydrology* 420, 171-182.
- Rumelhart, D.E., Hintont, G.E., Williams, R.J. 1986. Learning representations by backpropagating errors. *Nature*, 323(6088), 533-536.
- Sjöberg, J., Zhang, Q., Ljung, L., Benveniste, A., Deylon, B., Gloennec, P.Y., Hjalmarsson, H., Juditsky, A., 1995. Nonlinear Black-Box Modeling in System Identification: a Unified Overview. *Automatica*, 31(12), 1691-1724.
- Stone, M., 1974. Cross-Validatory Choice and Assessment of Statistical Predictions. *Journal of the Royal Statistical Society, Series B (Methodological)* 36(2),111-147.
- Thirel, G., V. Andréassian, C. Perrin, J.-N. Audouy, L. Berthet, P. Edwards, N. Folton, C. Furusho, A. Kuentz, J. Lerat, G. Lindström, E. Martin, T. Mathevet, R. Merz, J. Parajka, D. Ruelland & J. Vaze. Hydrology under change. An evaluation protocol to investigate how hydrological models deal with changing catchments. *Hydrological Sciences Journal*, 2014, this issue.
- Toukourou, M., Johannet, A., Dreyfus, G., 2009. Flash Flood Forecasting by Statistical Learning in the Absence of Rainfall Forecast: A Case Study. *Engineering Applications of Neural Networks*, 98–107.
- Toukourou, M., Johannet, A., Dreyfus, G., Ayrat, P.-A., 2011. Rainfall-runoff modeling of flash floods in the absence of rainfall forecasts: the case of “Cévenol flash floods”. *Journal of Applied Intelligence*, 35(2), 1078-189.
- Van Den Boogaard, H., Mynett, A., 2004. Dynamic neural networks with data assimilation, *Hydrological Processes*, 18, 1959–1966.
- Vaze, J., Chiew, F., Potter, N., Post, D., Petheram, C., Lerat, J., Teng, J., Wang, B., (2013). Modelling experiments with conceptual rainfall-runoff models under non-stationary conditions. Workshop-IAHS.
- Yu, B., Zhu, Z., (2013). A comparative assessment of AWBM and SimHyd for forested watersheds. Workshop-IAHS.

## Appendix


### Derivative computation thanks to back-propagation

The aim of this appendix is to provide explanations on the method to implement adaptivity or variational data assimilation in the neural formalism. We will express the derivative of the output with respect to the input variable  $u_j$  (for data assimilation) and with respect to the parameter  $w_{ij}$  (for adaptivity). The same calculation applies to others inputs variables or parameters.

For sake of simplicity one considers only a specific example;  $k$  is thus constant and omitted. To calculate the cost function minimization using a gradient descent we have to compute the derivative ( $q$  is the observed targeted variable, the discharge in our work):

$$\frac{\partial J(\mathbf{u}, \mathbf{w})}{\partial w_{ij}} = \frac{\partial (q - s(\mathbf{u}, \mathbf{w}))^2}{\partial w_{ij}} = -2(q - s(\mathbf{u}, \mathbf{w})) \frac{\partial s(\mathbf{u}, \mathbf{w})}{\partial w_{ij}} \quad (13)$$

This derivative necessitates to compute the derivative of  $s(\mathbf{u}, \mathbf{w})$  with respect to  $w_{ij}$ , respectively  $u_j$ .



**Fig. A1** Part of a multilayer perceptron.

One more time for sake of simplicity we consider a part of a general multilayer perceptron network, as shown in Fig. A-1. In this architecture each neuron has two variables of interest: the potential and the output. The derivative of the output of the network ( $s_z$ ) can thus be computed by decomposing the derivative through each variable of interest from the output of the network towards the input. With the notations of the Fig. A-1, and for the path connecting the output (neuron  $z$ ) to the input ( $u_j$ ) via the neuron  $i$ , this can be expressed as, considering the general equation 1 ( $\mathbf{w}_i$  is the column  $i$  of the matrix  $\mathbf{w}$ , corresponding to the vector of the parameters connecting the input ( $u_j$ ) to the neuron  $i$ ):  $v_i^k = \mathbf{u}^k \mathbf{w}_i$ , and  $s_i^k = f(\mathbf{u}^k \mathbf{w}_i)$ :

$$\frac{\partial s_z}{\partial w_{ij}} = \frac{\partial s_z}{\partial v_z} \frac{\partial v_z}{\partial s_i} \frac{\partial s_i}{\partial v_i} \frac{\partial v_i}{\partial w_{ij}} = f'(v_z) w_{zi} f'(v_i) u_j \quad (14)$$

Respectively for data assimilation, it provides:

$$\frac{\partial s_z}{\partial u_j} = \frac{\partial s_z}{\partial v_z} \frac{\partial v_z}{\partial s_i} \frac{\partial s_i}{\partial v_i} \frac{\partial v_i}{\partial u_j} = f'(v_z) w_{zi} f'(v_i) w_{ij} \quad (15)$$

Based on these derivatives calculations, the Hessian matrix  $\mathbf{H}$  can be built and the Levenberg-Marquardt rule applied as it was when calculating a standard training.

### 3.3.3. À RETENIR

Ces travaux, menés dans le cadre de l'étude d'adaptation des modèles aux non-stationnarités, permettent de souligner l'intérêt et la souplesse des réseaux de neurones comme outils de modélisation, qui plus est, en conditions non-stationnaires.

Cet article présente une comparaison des modèles récurrent et non-récurrent auxquels sont appliqués l'adaptativité et l'assimilation de données dans un contexte non-stationnaire. De façon générale, on constate que les modèles récurrents et non-récurrents ont de bonnes capacités de généralisation et ce même en conditions non-stationnaires. Il est possible de voir que le modèle « nourri » par des informations de sorties mesurées (modèle non-récurrent) est plus performant que celui utilisant des informations estimées (modèle récurrent). Néanmoins, il est tributaire de la qualité de la base de données. Dans ce cas, au niveau de la prise en compte des données par le modèle, un poids important est donné à l'information de sortie. Les entrées, telles que la pluie, servent à calculer les changements rapides de la sortie du système (taille des fenêtres temporelles de précipitations réduite à quelques jours). Pour le modèle récurrent, l'estimation de la sortie est une étape importante qui s'effectue souvent au détriment de la représentation des hautes fréquences correspondant à la contribution de la pluie à court terme. C'est là que réside la différence de qualité entre les deux modèles. Néanmoins, il apparaît que l'utilisation de l'assimilation de données pour corriger les précipitations, permet de très nettement améliorer le modèle récurrent qui va donc pouvoir prendre en compte les changements d'états rapides dus aux précipitations. Dans certains cas, le modèle récurrent adapté aux non-stationnarités peut se montrer aussi performant, voire à peine meilleur que le modèle non-récurrent.

La différence majeure entre les méthodes d'adaptativité et d'assimilation de données réside dans la cible des modifications. En effet, l'adaptativité est appliquée pour modifier les paramètres du modèle qui ont été ajustés durant la phase d'apprentissage. Or, ces paramètres sont ajustés pour un ensemble d'apprentissage donné (avec en plus l'application de méthodes de régularisation : validation croisée ; arrêt précoce) auquel correspond un fonctionnement hydrodynamique général. De ce fait, si le fonctionnement hydrodynamique du système est modifié, les paramètres ajustés sont susceptibles de ne plus être en adéquation avec le système modifié. Dans ce cas, la méthode d'adaptativité peut permettre de corriger les valeurs des paramètres afin de rendre le modèle représentatif du fonctionnement hydrodynamique enregistré en sortie du système.

L'assimilation de donnée apporte une correction des variables d'entrée à partir de la variable de débit assimilée. Or, on constate par exemple que dans le cas de la Durance le modèle récurrent est capable de fournir une sortie acceptable, qui se voit considérablement améliorée par l'utilisation de l'assimilation pour modifier les données de pluie en entrée. Il apparaît donc que le calage des paramètres du modèle est satisfaisant mais que les données en entrée subissent des modifications qui sont susceptibles d'être indépendantes du fonctionnement hydrodynamique comme par exemple la modification des pluies mesurées par l'évapotranspiration.

La méthode d'assimilation de données proposée dans ce chapitre sera utilisée dans le chapitre 5 pour développer une première approche de modélisation inverse à partir d'un modèle par réseaux de neurones pour combler d'éventuelles lacunes.

## 3.4. CONCLUSIONS GÉNÉRALES DU CHAPITRE 3

L'objectif de ce chapitre est de présenter des méthodes de modélisation complémentaires de l'analyse systémique présentée au chapitre 2. Les réseaux de neurones, présentés dans ce chapitre, ont en effet la capacité d'apprendre le fonctionnement non-linéaire d'un système naturel complexe comme celui d'un hydrosystème karstique (chapitre 1). De plus, la robustesse, la souplesse, les capacités d'apprentissage et de généralisation des réseaux de neurones en font des outils transposables à tous les systèmes disposant d'une base de données suffisante pour permettre l'apprentissage. Ainsi, le premier article présenté dans ce chapitre



(Johannet et al., 2012b) a permis de présenter les réseaux de neurones et leur application à la modélisation hydrodynamique des karsts.

Nous avons ainsi vu que ces modèles ne sont pas restreints à une approche de type « boîtes noires ». Il est en effet possible de contraindre le modèle par réseau de neurones, soit : i) à partir de connaissances physiques, c'est une approche semi-physique appelée « boîtes grises », ii) à partir d'un modèle conceptuel pour lequel chaque bloc est représenté par un réseau de neurones, cette approche appelée « boîtes transparentes » permet d'extraire la sortie de chaque bloc pour obtenir des informations sur le processus qu'il représente, iii) à partir d'informations sur le fonctionnement hydrodynamique obtenues à partir de l'analyse systémique.

Il nous est donc possible de contraindre le modèle, mais aussi d'en extraire des informations sur des processus supposés ou encore sur la contribution relative de pluies spatialisées (Kong-A-Siou et al., 2013). Ces travaux ont pu être menés grâce à une investigation approfondie des paramètres du modèle. L'investigation des paramètres du modèle conduira, au chapitre 5, à proposer une représentation de la réponse impulsionnelle (pluie-débit) générée à partir de différentes architectures de réseaux de neurones.

La possibilité de contraindre et d'exploiter les réseaux de neurones pour que le modèle ou ses sorties soient représentatifs du système naturel est un point essentiel qui leur permet d'apporter une approche pertinente et complémentaire aux méthodes d'étude et de caractérisation présentées aux chapitres 1 et 2.

Le second article présenté dans ce chapitre (Taver et al., 2014) aborde la question de la non-stationnarité, qu'elle soit due à une modification du système ou de ses entrées. Deux modèles (récurrent et non-récurrents) ont été confrontés à ces conditions non-stationnaires pour deux bassins versants aux propriétés très différentes (taille, type de non-stationnarité...). Parallèlement, les méthodes d'adaptativité et d'assimilation de données sont respectivement utilisées pour modifier les paramètres du modèle ou certaines de ses entrées.

L'utilisation des modèles récurrents et non-récurrents a confirmé, dans un premier temps, le fait que malgré des résultats souvent éloignés, les deux modèles présentent des avantages qui leur sont propres. Le modèle non-récurrent a montré son efficacité pour la modélisation et la prévision, lorsque la mesure de l'information de sortie est fiable et complète. Le modèle récurrent n'est pas limité par la disponibilité de l'information de sortie mesurée, puisqu'elle n'est pas utilisée comme entrée par le modèle. Ce modèle, généralement moins performant, présente l'avantage de pouvoir travailler avec des prévisions météorologiques, où même avec des données issues des scénarios de changement climatiques.

L'étude de ces deux modèles en conditions non-stationnaires a permis de vérifier leur capacité de généralisation à un système perturbé ou en évolution. Dès lors, des méthodes d'ajustement en temps réel, des entrées ou des paramètres du modèle, ont été appliquées afin d'améliorer les résultats.

La méthode d'adaptativité modifie les paramètres du modèle et donc la façon dont ce système artificiel prend en compte ses entrées. L'utilisation de cette méthode dans le cas d'un bassin dont les propriétés hydrologiques ont été modifiées (cas du bassin de Fernow) aurait sans doute donné de meilleurs résultats si le pas d'échantillonnage des données avait été adapté à la taille du bassin.

Le modèle dont les performances ont montré la plus nette amélioration est le modèle récurrent auquel a été appliquée l'assimilation de données. Le modèle récurrent associé à l'assimilation de données permet d'obtenir un modèle, non alimenté par la mesure de sa sortie aux temps précédents, qui peut être amélioré en temps réel pour obtenir une meilleure représentation du fonctionnement hydrodynamique du karst. Ces résultats s'expliquent par le fait que le système n'a pas subi de modifications significatives alors que les forçages ont été modifiés. Or, nous avons vu que l'assimilation de données, telle qu'elle a été présentée dans ce chapitre, modifie les entrées pour obtenir la meilleure sortie possible.

Finalement, les outils de modélisation présentés dans ce chapitre vont être appliqués au chapitre 5 à l'hydrosystème karstique du Lez présenté dans le chapitre suivant (chapitre 4). Ces modèles seront exploités pour améliorer la connaissance sur le fonctionnement du système naturel, mais aussi sur le système artificiel

qu'est le réseau de neurones. L'étude conjointe du système naturel et du système artificiel permet de contraindre le système artificiel pour que celui-ci soit plus en adéquation avec le système naturel.

L'assimilation de données sera également appliquée à l'hydrosystème karstique du Lez à la fin du chapitre 5. Elle sera utilisée non-seulement pour améliorer la sortie du modèle, mais aussi pour développer une approche de modélisation inverse à partir d'un modèle non-linéaire qui sera décrite plus tard au chapitre 5. Nous verrons que ce type d'approche ouvre des possibilités considérables, surtout en termes d'estimation des variables efficaces en entrée, ou encore pour compléter des séries comportant des lacunes.



# 4. L'AQUIFERE KARSTIQUE DU LEZ

## 4.1. INTRODUCTION

Dans ce travail, l'hydrosystème karstique du Lez est utilisé comme cas d'étude. Ce chapitre a pour objet la présentation de cet hydrosystème sous de multiples facettes qui contribuent à pouvoir le qualifier de complexe.

Les premières études du fonctionnement hydrodynamique de l'aquifère karstique du Lez datent de la fin du XIX<sup>ème</sup> siècle avec la coloration de H. Bertin-Sans qui tenta d'établir, sans succès, la liaison entre le Lirou et la source du Lez. Depuis, les études se sont succédées, permettant ainsi l'acquisition de données relatives au fonctionnement hydrodynamique (piézométrie, température, conductivité, traçages, etc.). Du fait d'une pression démographique accrue, l'étude de l'hydrosystème du Lez a connu un essor considérable pendant la seconde moitié du XX<sup>ème</sup> siècle (Drogue, 1964; Marjolet and Salado, 1976 ; Paloc, 1979 ; Thiéry et al. 1983). Ces travaux ont permis d'acquérir une connaissance importante du fonctionnement hydrodynamique, mais aussi d'appréhender le bassin hydrogéologique. L'ensemble de ces travaux a conduit à mettre en place, dans les années 80, un système de gestion active de la ressource souterraine qui fait toujours référence à l'heure actuelle.

Néanmoins, les complexités géomorphologique et hydrodynamique de l'aquifère du Lez en font un objet toujours très étudié par la communauté scientifique régionale. On peut citer le « Projet gestion multi-usages de l'hydrosystème karstique du Lez »<sup>4</sup>, qui rassemble les travaux récents de scientifiques de différents organismes et spécialités, afin d'améliorer la connaissance et la représentation du système en vue d'une meilleure gestion de la ressource à fort intérêt socio-économique et d'une meilleure anticipation des crues de surface du Lez. Les impacts des changements climatiques, environnementaux et de gestion ont été analysés sur la ressource et sur les crues conduisant ainsi à de multiples publications.

Pour les décennies à venir différents points vont être indispensables à approfondir pour être en mesure de subvenir aux besoins locaux en eau tout en préservant la pérennité de la ressource. De façon non exhaustive, on peut citer les points suivants : l'extension profonde de l'aquifère et particulièrement au niveau de la station de pompage afin de connaître les ressources mobilisables ; l'optimisation des prélèvements ; la vulnérabilité qualitative et quantitative de la ressource.

C'est pourquoi il nous paraît que cet hydrosystème très étudié est un bon support pour le développement méthodologique d'un modèle contraint par la connaissance antérieure et susceptible de fournir des informations sur son fonctionnement hydrodynamique.

Ainsi, ce chapitre aborde, dans un premier temps, le contexte géographique, climatique, hydrologique, anthropique et géologique de l'hydrosystème karstique du Lez. Dans un second temps, les connaissances hydrogéologiques du système sont présentées afin de mieux appréhender son fonctionnement hydrodynamique ; enfin les principaux modèles hydrodynamiques précédemment développés sur le Lez seront succinctement présentés dans une dernière partie.

---

<sup>4</sup> \*Ce projet, nommé par la suite « projet Lez GMU » est financé par l'Agglomération de Montpellier, l'Agence de l'eau, le conseil général de l'Hérault (CG34), le BRGM. Porté par le BRGM avec pour partenaires scientifiques : G-EAU ; HSM ; CERFACS ; BIOTOPE ; TETIS. Ce projet a été le cadre de collaborations avec entre autre : l'EMA, le SPC Méditerranée Ouest et le SCHAPI.

## 4.2. CONTEXTE

### 4.2.1. GEOGRAPHIE ET CLIMAT

Situé au Sud-Est de la France, dans l'Hérault, le Lez prend sa source au nord de Montpellier. Il parcourt une trentaine de kilomètres et traverse plusieurs communes avant de se jeter dans la mer Méditerranée au niveau de Palavas-les-Flots. Le Lez traverse la ville de Montpellier, qui du fait de sa démographie en croissance continue a reconnu son importance en terme de ressource en eau depuis des décennies.

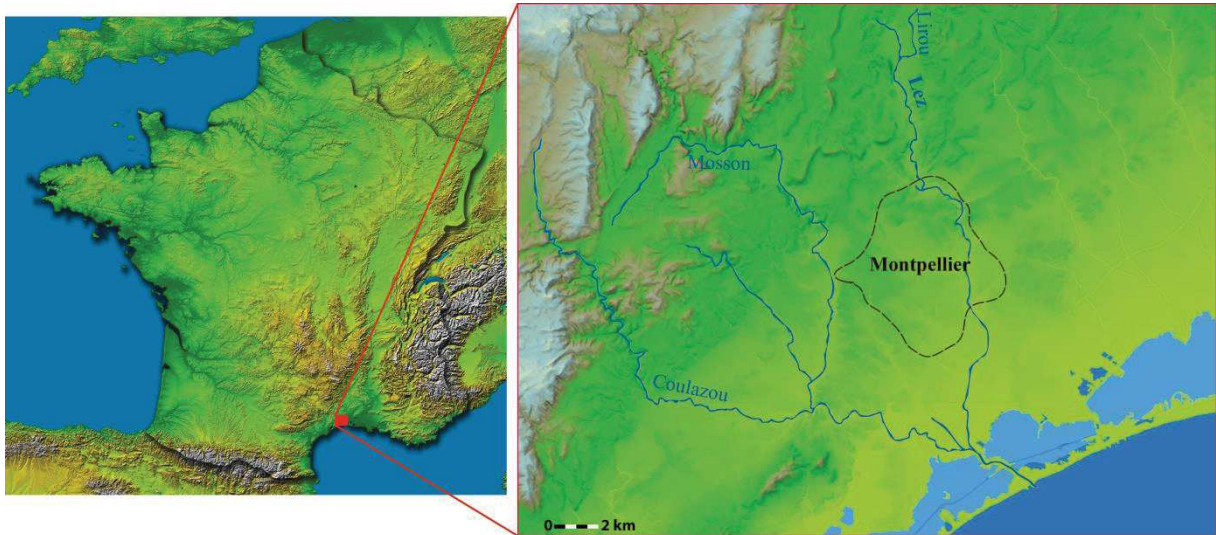


Figure 16 : Cartes de localisation du Lez et de ses principaux affluents : Coulazou, Mosson et Lirou. Réalisée d'après les données Géoportail.

La source du Lez occupe une place très importante pour l'agglomération montpelliéraine, car elle assure la pérennité de la ressource en eau, en dépit du climat méditerranéen. Ce dernier est caractérisé par des étés chauds et secs et des hivers doux avec des températures moyennes ne passant pas sous les 5°C (Figure 17).

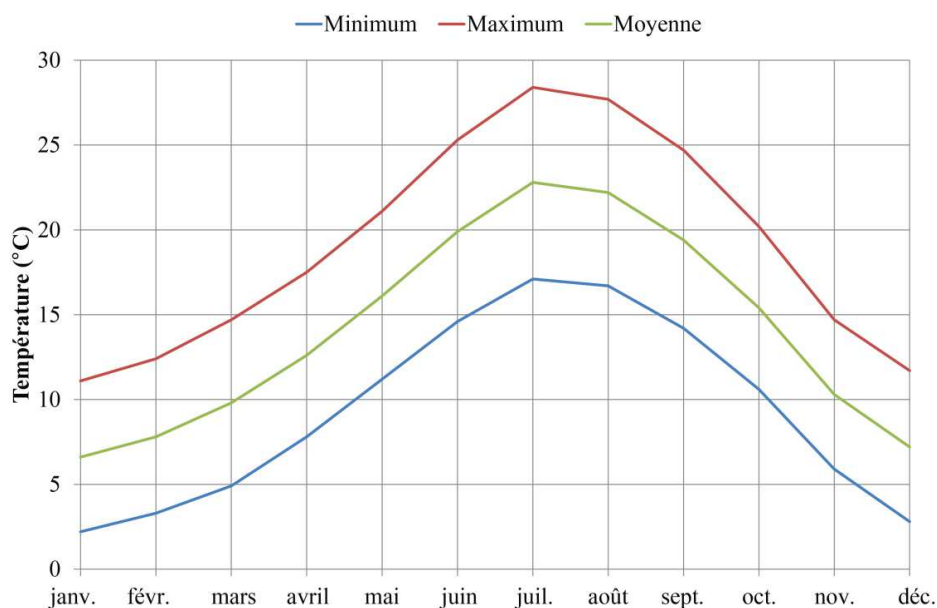


Figure 17 : Températures mensuelles interannuelles enregistrées à la station de Montpellier-Fréjorgues sur la période 1961-1990.

Les processus météorologiques et climatiques n'étant pas l'objet de ce travail, ces derniers sont brièvement abordés. Pour plus de détails, le lecteur pourra se référer à Harader et al. (soumis à Climate Dynamics en octobre 2014).

Paradoxalement, avec seulement une soixantaine de jours de précipitations par an, le bassin du Lez présente un cumul annuel variant entre 600 mm pour la zone littorale et 1200 mm en s'approchant des reliefs. Ces valeurs traduisent d'une part, une variabilité spatiale importante sur le bassin, et d'autre part, l'occurrence d'événements intenses. En effet, si l'on compare avec Paris, où le cumul annuel moyen enregistré est de 640 mm pour environ 170 jours de pluie, les valeurs observées sur le bassin du Lez ne peuvent être associées qu'à l'intensité des rares précipitations. En Languedoc-Roussillon, l'intensité des précipitations peut aisément dépasser 400 mm en 24h, soit près de la moitié du cumul annuel moyen observé sur le bassin du Lez. Récemment, l'épisode du 29 septembre 2014 survenu sur le Languedoc-Roussillon et plus particulièrement dans l'Hérault a battu plusieurs records avec 180 mm de précipitations en 2h et 250 mm en 3h. Cet épisode a fait la « une » des médias du fait des intensités enregistrées, mais aussi à cause de la montée des cours d'eau et des conséquences dans les zones urbanisées. La saturation des sols et des réseaux de collecte de pluie ont entraîné un fort ruissellement, on peut en effet voir sur la Figure 18 que de nombreuses rues se sont vues transformées en cours d'eau capables de charrier une quantité importante de matière solide.



Figure 18 : Rue du village des Matelles. (a) pendant l'événement du 29/09/2014. (b) lors d'une accalmie pendant l'événement du 06/10/2014.

La situation géographique du bassin du Lez, entre la mer Méditerranée et les Cévennes, explique ces phénomènes météorologiques intenses. En effet, on distingue deux types de précipitations qui affectent le bassin du Lez : i) les précipitations stratiformes, ii) les précipitations convectives et orographiques.

Les premières, généralement de faibles intensités, sont associées à l'élévation le long d'un front (pente douce) de flux marins chauds et humides. Ces systèmes peuvent toutefois contenir des cellules convectives qui alimentent l'intensité des précipitations. Dans le cas du Lez, Coustau et al. (2012) ont montré que ces systèmes pouvaient être à l'origine de crues éclair.

La mise en place d'un système de précipitations convectives est due à l'élévation rapide de l'air chaud et humide ce qui entraîne le déclenchement de pluies intenses, stationnaires et souvent très localisées. Dans certains cas, un système convectif de méso-échelle, en « V » quasi-stationnaires, se met en place et a la capacité de s'auto-régénérer causant ainsi des précipitations d'une très forte intensité, très localement. Ces phénomènes se produisent essentiellement à l'automne du fait de la température élevée de la méditerranée après la saison chaude. Ces épisodes sont appelés « méditerranéens ». C'est le type d'épisode observé le 6 octobre 2014 dont le cumul atteint est de 230 mm. Cet épisode s'est concentré sur une partie du bassin du Lez causant ainsi la montée très rapide du Lez et de ses affluents et générant ainsi des dégâts considérables comme ceux qui ont pu être observé à Grabels.

Dans la suite de ce travail les précipitations sont décrites et analysées pour la période 1950-1967, période sur laquelle nous avons étudié l'hydrosystème du Lez. Le choix de cette période a été motivé par la volonté d'étudier la relation pluie-débit la moins perturbée par d'autres forçages, en particulier les forçages anthropiques comme les pompages. Les pompages de la source du Lez, dont les modalités seront détaillées par la suite, ont débuté en 1968 et ont considérablement évolué en 1982 pour devenir ce que nous connaissons actuellement. L'impact des prélèvements peut, selon certains auteurs, prendre des formes différentes : i) la modification des caractéristiques initiales du système (Dörfliger et al., 2008), ii) la sollicitation accrue de certaines zones périphériques associée au rabattement induit par le pompage (Ladouche et al., 2014).

#### 4.2.2. HYDROGRAPHIE

Encadré à l'ouest par l'Hérault et à l'est par le Vidourle, le Lez est un fleuve ; il reçoit les apports de plusieurs affluents temporaires ou pérennes : le Lirou, le Verdanson et la Mosson au niveau des étangs palavasiens (Figure 16). L'apport de ces rivières, des eaux de ruissellement pluvial et des sources karstiques contribuent à l'augmentation du débit du Lez qui peut atteindre 500 m<sup>3</sup>/s à la station de Lavalette. Cette valeur est importante pour un fleuve très court, dont le bassin hydrogéologique s'étend sur environ 380 km<sup>2</sup> pour un bassin topographique à Lavalette de 114 km<sup>2</sup>. Afin de maintenir un débit biologique minimum en étiages, le Lez est également alimenté si nécessaire d'une part par un débit réservé de 180L/s en aval immédiat de la source, puis, en aval de la station de Lavalette par le canal BRL (Bas Rhône Languedoc) qui peut débiter 500 L/s par point de rejet dans le Lez.

Tableau 1 : Réactions de l'hydrosystème, en fonction de l'état initial, à deux événements aux cumuls proches.

| Episode    | Cumul de pluie j (mm) | Piézométrie initiale (m) | Piézométrie fin (m) | Q source (m <sup>3</sup> /s) | Q Lavalette (m <sup>3</sup> /s) | Q Garigliano (m <sup>3</sup> /s) |
|------------|-----------------------|--------------------------|---------------------|------------------------------|---------------------------------|----------------------------------|
| 09/10/2001 | environ 120           | 66                       | 68.5                | 24                           | 238                             | 314                              |
| 24/08/2002 | environ 130           | 43                       | 64                  | 0                            | 6                               | 8                                |

Les événements pluvieux récents déjà évoqués précédemment ont eu des impacts très différents en terme de débit puisque pour l'événement du 29 septembre 2014 le débit enregistré à Lavalette était de 350 m<sup>3</sup>/s alors que pour l'événement du 6 octobre 2014 il a atteint 500m<sup>3</sup>/s. L'état de l'hydrosystème a donc une incidence prépondérante comme le soulignent les débits observés pour les événements consignés dans le Tableau 1. Ces observations confirment de rôle d'écrêteur de crue effectué par l'aquifère sur les premières crues d'automne du fait des pompages estivaux.



Figure 19 : Lez au niveau de l'Hôtel de région dans sa partie aménagée lors de la crue du 29 septembre 2014. Bogdan – Midi Libre.

Le Lez subit une importante pression anthropique, que ce soit en termes d'aménagement (Figure 19), de rejets de stations d'épurations, ou encore de prélèvements agricoles. Mais la principale pression anthropique qui affecte la ressource, détaillée dans la section suivante, correspond à l'exploitation de sa source pour l'alimentation en eau potable de l'agglomération montpelliéraine.

#### 4.2.3. EXPLOITATION DE LA SOURCE DU LEZ

Le climat méditerranéen et la pression démographique ont fait de la source du Lez une ressource essentielle pour la ville de Montpellier. En effet, le faible nombre de jours de pluie et leur répartition saisonnière constituent des apports irréguliers qui seraient manifestement insuffisants si l'hydrosystème du Lez n'avait la capacité de stocker l'eau dans le temps. Cette capacité de stockage permet donc une exploitation, nécessairement raisonnée, pour les besoins locaux en eau potable.

La source du Lez est captée depuis 1854, à cette époque la vasque a été aménagée de façon à relever le niveau de débordement de la source afin de prélever, par gravité, un débit par un orifice à la base de ce mur de relèvement. En 1934, une conduite d'un mètre de diamètre est installée, avec sa partie supérieure à la cote de 63,5 mNGF. En 1949, le seuil est rehaussé pour atteindre 64,91 mNGF et permettre un prélèvement plus important. Jusqu'en 1968, les prélèvements ont ainsi été effectués par gravité (Figure 20) au niveau de la vasque. Ce type d'exploitation n'engendre pas de perturbations majeures du fonctionnement hydrodynamique de l'aquifère. Il est toutefois possible que l'augmentation du niveau de l'exutoire principal ait eu un impact sur le fonctionnement ou sur l'apparition d'exutoires temporaires. Les débits gravitaires prélevés sont de l'ordre de 400 L/s. Or, la démographie croissante de la ville de Montpellier a engendré en quelques décennies une augmentation des besoins en eau potable. De ce fait, à partir de 1968, l'exploitation est réalisée grâce à des pompes prélevant l'eau au fond de la vasque (Figure 20), permettant ainsi un rabattement de l'ordre de 7 m. Ce système d'exploitation de la source a produit un débit d'environ 800 L/s en fonction des saisons. Le fait de rabattre le niveau piézométrique de la vasque de 7m engendre une perturbation modérée du système, mais difficilement quantifiable. En effet, selon certains auteurs, la sollicitation de zones situées en dessous du niveau de l'exutoire serait susceptible d'entraîner des modifications de comportement de l'hydrosystème notamment par décolmatages de fractures ou de cavités ou soutirages (Dörfliger et al., 2008).





Figure 20 : Observation des aménagements de la source du Lez asséchée par les pompages effectués en amont de la source (septembre 2013).

Le constat de l'insuffisance de ce type d'exploitation de l'aquifère fut un moteur pour l'étude hydrogéologique de l'aquifère du Lez. L'amélioration de la connaissance du système permit, en 1982, la mise en place d'un système d'exploitation de la ressource tout à fait novateur pour l'époque. En effet, le professeur Avias, hydrogéologue montpelliérain, proposa la mise en place d'une station de pompage souterraine afin d'exploiter l'hydrosystème jusque dans des profondeurs plus importantes en amont de la source grâce à son caractère vaclusien. Ainsi, au niveau du drain principal, les pompes prélèvent à une cinquantaine de mètres sous le niveau de débordement de la vasque. Associée à la capacité d'assécher complètement la source, une déclaration d'utilité publique interdit un rabattement supérieur à 30 m sous le niveau de débordement de la vasque et les débits maximums de prélèvement autorisés sont de 1700 L/s. Cette limite de rabattement est fondée sur le manque de connaissance de l'extension profonde de l'aquifère, mais aussi sur la crainte d'une perturbation du système qui pourrait entraîner une augmentation de la turbidité ou des effondrements risquant de colmater le conduit principal. Néanmoins, pour les décennies à venir, un défi passionnant serait de combler ces lacunes de connaissance quant à l'extension profonde de l'aquifère et à son comportement face à une augmentation du rabattement.

La mise en place de ce système d'exploitation engendre un assèchement de la source, selon les saisons, qui est faiblement compensé par la restitution d'une partie du débit prélevé (160 L/s). Ce débit de restitution de 160 L/s correspond aux valeurs observées lors des étiages, il permet d'éviter un assèchement du fleuve qui aurait des conséquences écologiques majeures, en particulier pour le Chabot du Lez qui est une espèce endémique de poisson.

Étant donné les perturbations engendrées par l'exploitation de l'hydrosystème du Lez depuis 1968, il a été décidé pour ce travail d'utiliser les données disponibles sur son fonctionnement quasi-naturel (avant 1968, le comportement de l'hydrosystème était faiblement perturbé par le relèvement du seuil de débordement et les prélèvements). Les données retenues, qui sont détaillées et analysées par la suite sont ainsi comprises dans la période 1950-1967.

#### 4.2.4. GEOLOGIE

##### 4.2.4.1. HISTOIRE GEOLOGIQUE REGIONALE

D'un point de vue géologique, le Languedoc-Roussillon présente une richesse considérable. En effet, les paysages que l'on peut observer résultent de près de 600 millions d'années d'histoire comme en témoignent les reliefs.

En premier lieu, les massifs tels que le Massif Central ou les Cévennes sont les vestiges de la chaîne Hercynienne formée à la fin du Paléozoïque. Les roches associées sont des roches métamorphiques, comme par exemple les schistes des Cévennes. Ces reliefs, bien que non représentés sur le bassin du Lez et donc

absents de la série stratigraphique (Figure 21), ont un impact sur le climat régional comme nous l'avons souligné précédemment. De plus, durant le Paléozoïque, des décrochements majeurs vont affecter ce socle et générer des failles qui vont conditionner les dépôts sédimentaires et les mouvements tectoniques ultérieurs (Arthaud et Seguret 1981).

L'ouverture de la Thétys durant le début du Mésozoïque entraîne le dépôt de sédiments d'abord continentaux et marins, puis essentiellement marins. La série du Trias est caractérisée par des dépôts de grès, d'argiles et d'évaporites.

La fin du Trias est marquée par une transgression marine qui va engendrer au début du Lias (Hettangien) le dépôt de grès, de marnes et de calcaires dolomitiques. La zone passe progressivement à un domaine plus profond au Sinémurien. Par la suite, au Toarcien et au début de l'Aalénien, la série sédimentaire essentiellement marneuse et argileuse se met en place (Figure 21).

| Hydrogéologie                | Etage et faciès dominant  | Epaisseur | Remarques  | Série                   | âge (Ma) |
|------------------------------|---|-----------|--|-------------------------|----------|
| Imperméable                  | Colluvions, alluvions   | <10m      |  | Quaternaire             | 2        |
|                              | Sables et conglomérats  | 0-300m    |  | Oligocène               | 23       |
| Aquifère                     | Lutétien - calcaires lacustres  | 50-100m   |  | Eocène                  | 34       |
| Imperméable                  | Vitrollien - marnes roses, brèches  | 40-300m   |  |                         | 53       |
| Aquifère                     | Hauterivien supérieur<br>Calcaires graveleux                                    | 100m      | Contact avec l'aquifère du Lez par la faille de Corconne     | Crétacé inférieur       | 96       |
| Imperméable                  | Hauterivien inférieur - Marnes  | 100m      |  |                         |          |
| Aquifère                     | Valanginien supérieur<br>Calcaires miroitants                                   | 50-200m   | Indépendant  |                         |          |
| Imperméable ou peu perméable | Valanginien inférieur<br>Marnes, marno-calcaires, bancs de calcaires intercalés | 200-800m  | Considéré comme toit de l'aquifère principal                 |                         |          |
|                              | Berriasien - calcaires durs et argileux   | 50-140m   | Massif de la source du Lez                                   |                         | 135      |
| Aquifère principal           | Kimmeridgien Portlandien<br>calcaires francs et calcaires argileux              | 150-250m  |  | Malm (Jurassique sup)   |          |
|                              | Sequanien - calcaires argileux en petits bancs                                  | 60-100m   |  |                         |          |
| Imperméable ou peu perméable | Argovien Rauracien - calcaires francs et calcaires argileux                     | 300m      | discontinuités tectoniques → échanges hydrauliques possibles |                         |          |
|                              | Oxfordien - Marnes bleues   | 20-50m    |  |                         |          |
|                              | Callovien - Marnes et calcaires marneux   | 80-100m   |  |                         | 154      |
| Aquifère                     | Bathonien - Calcaires à chailles dolomies                                       | 50-300m   |  | Dogger (Jurassique moy) |          |
|                              | Bajocien Aalénien supérieur<br>Calcaires siliceux, marnes                       | 100-150m  | Perte diffuse vers ce niveau (Combe de Mortiers)             |                         |          |
| Imperméable                  | Aalénien inférieur Toarcien<br>Domérien - Argiles, marnes noires                | 150-400m  | Fort ruissellement (Combe de Mortiers)                       | Lias (Jurassique inf)   | 175      |

Figure 21 : Log géologique et hydrogéologique schématique de l'aquifère du Lez d'après G. Marjolet et J. Salado (1976) et P. Bérard (1983).

Ensuite, durant le Dogger (Bajocien, Bathonien), de puissants dépôts carbonatés (calcaires et dolomie) se mettent en place sur une plate-forme reconstituée. Cette période est aussi marquée par le rifting de la Téthys qui entraîne une différenciation de la zone sédimentaire. Le Callovien et l'Oxfordien sont marqués par une forte concentration de sédiments marneux du fait d'une subsidence tectonique. Durant le début du Malm, à l'Oxfordien supérieur, la formation de roches carbonatées reprend progressivement, avec un passage par des alternances marno-calcaires, pour aboutir enfin aux calcaires à tendance argileuse de la fin du Malm. Durant le

début du Crétacé, la formation de roches carbonatées continue avec les calcaires du Berriasien (Figure 21). Par la suite, les dépôts se font sous forme d'une alternance de calcaires, de marno-calcaires et de marnes pendant le Valanginien et l'Hauterivien, qui sont les seuls étages représentés dans la région pour le Crétacé qui connaît une phase de régression.

En effet, dès le Crétacé supérieur, la collision de l'Espagne avec l'Europe entraîne le début de la phase pyrénéenne. Durant cette période, l'eustatisme global atteint son plus haut niveau (+ 220 m NGF).

Dans la région, le Tertiaire est plus marqué par une forte activité tectonique que par la sédimentation. En effet, les orogénèses pyrénéenne et alpine ainsi que l'ouverture du Golfe du Lion affectent les roches existantes et sculptent, en partie, le paysage actuel. Les variations eustatiques ont pour effet de favoriser l'érosion et la karstification.

Durant l'Eocène, la compression pyrénéenne entraîne un décollement des sédiments du Trias et engendre le chevauchement de Montpellier ainsi que les plis d'axe Est-Ouest et une fracturation importante des niveaux mésozoïques. Pendant cette période, des dépôts de marnes roses, de brèches et de calcaires lacustres se mettent en place sur des terrains déjà érodés (contact entre le Jurassique supérieur et les terrains de l'Eocène).

Entre l'Eocène et l'Oligocène, la dynamique compressive entraîne le jeu de la faille des Cévennes, et d'autres failles de moindre amplitude, en décrochement.

L'ouverture du Golfe du Lion à l'Oligocène engendre une phase extensive qui fait rejouer les failles de l'Eocène, mais cette fois en failles listriques. Ces épisodes tectoniques sont à l'origine de fossés qui se remplissent et subsident en même temps. Le remplissage donne lieu aux dépôts de sables et conglomérats.

Après un épisode transgressif caractéristique, le Miocène est marqué par la remontée de l'Afrique qui entraîne la fermeture du détroit entre l'Atlantique et la Méditerranée. Cet épisode aboutit, au Messinien, à un assèchement de la Méditerranée qui correspond à la crise messinienne durant laquelle le niveau de la mer Méditerranée s'est abaissé de plus de 1500 m. Cet événement majeur engendre un surcreusement des réseaux hydrographiques superficiels (Figure 22) et souterrains (Clauzon, 1982 ; Audra et al., 2004 ; Husson, 2013).

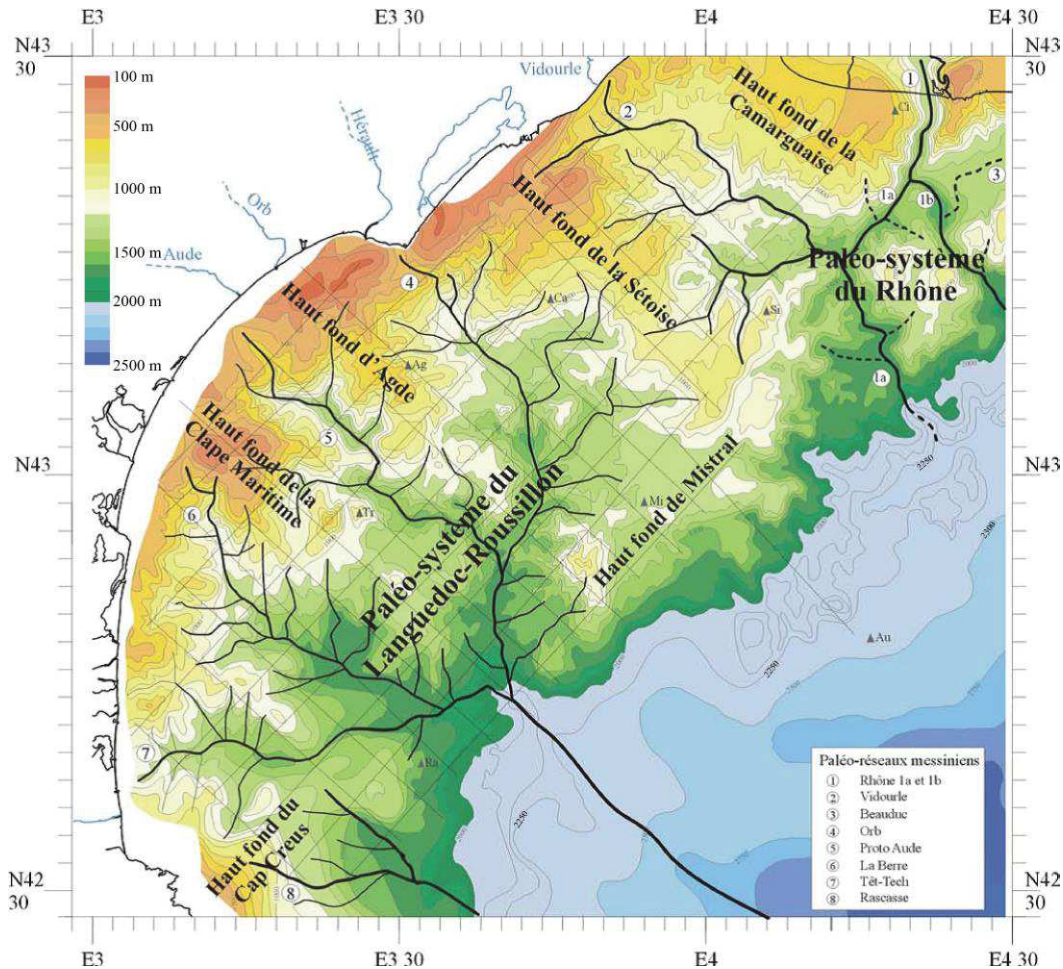


Figure 22 : Carte des isobathes de la surface d'érosion messinienne de la plate-forme du Golfe du Lion (Lofi, 2002, modifiée d'après Guennoc et al., 2000). Dans la vallée du Languedoc-Roussillon, le réseau détaillé des fleuves messiniens et de leurs affluents a été établi à partir des nouvelles données de la campagne LRM96.

La crise messinienne prend fin au début du Pliocène par une remontée du niveau marin qui connaîtra toutefois de fréquentes fluctuations. La sédimentation du Quaternaire correspond à des dépôts continentaux (alluvions, colluvions).

L'histoire géologique, tectonique et eustatique régionale est essentielle pour la compréhension du développement polyphasé du système karstique du Lez.

#### 4.2.4.2. STRUCTURE GEOLOGIQUE DU BASSIN DU LEZ

La géomorphologie actuelle du bassin hydrogéologique de la source du Lez est un point essentiel pour la compréhension de son fonctionnement, de son alimentation et de son émergence. La complexité géomorphologique du bassin réside essentiellement dans les deux phases tectoniques majeures du Cénozoïque : i) la compression pyrénéenne, ii) l'extension oligocène.

La dynamique compressive a engendré le plissement des formations existantes générant ainsi des reliefs tels que le Pic Saint-Loup (Figure 23) ou encore des discordances comme au niveau du chevauchement de Montpellier. La faille de Corconne, qui parcourt et sépare en deux le bassin, est un témoin de cette phase de compression.




Figure 23 : Coupe schématique générale du bassin du Lez. Kong A Siou (2011) modifié d'après M. Bonnet et M. Mattauer (2010)

L'extension Oligocène, qui a fait rejouer les décrochements en failles normales, est responsable de la formation des bassins en demi-grabens ainsi que des contacts entre les calcaires du Jurassique et les niveaux marneux du Valanginien inférieur.

Sur le bloc diagramme présenté dans la section Hydrogéologie en Figure 24, on constate 4 zones correspondant à différents types d'affleurements. Au nord-ouest de la faille de Corconne, une série crétacée, avec une base de Jurassique supérieur, peu tectonisée. La partie sommitale de cette série correspond au causse de l'Hortus.

La zone située au sud-ouest laisse apparaître les affleurements du Lias et du Dogger (combe de Mortiers) et du Malm (Pic Saint-Loup et causse de Viols-le-Fort) affectés par un réseau de failles au niveau de la combe de Mortiers.

La zone située à l'est de la faille de Corconne présente essentiellement des affleurements du Crétacé, et particulièrement ceux du Valanginien inférieur et de l'Hauterivien. On trouve aussi des affleurements Tertiaires dans les bassins Oligocènes (bassin de Saint-Mathieu-de-Trévières, bassin d'Assas). On y note aussi une importante fracturation dont une partie selon le même axe que la faille de Corconne.

La partie sud du bassin correspond au chevauchement de Montpellier où affleurent les terrains Eocènes et Oligocènes essentiellement détritiques à l'exception des calcaires du Lutétien.

## 4.3. HYDROGEOLOGIE

### 4.3.1. KARSTIFICATION

L'histoire géologique régionale est marquée par des variations eustatiques d'amplitudes plus ou moins importantes. Ces fluctuations ont entraîné des émergences de certaines séries carbonatées, entraînant ainsi des phases de karstification superficielles et localisées durant le Jurassique.

Dans la région montpelliéraine, une phase de karstification majeure débute au Crétacé supérieur, affectant ainsi les terrains du Jurassique et du Crétacé, du fait de leur émergence.

Durant le début du tertiaire, l'émergence de la zone, par surrection et par variation eustatique, rend les conditions propices au développement du karst en profondeur, aussi favorisé par une intense fracturation héritée de l'orogénèse pyrénéo-alpine. La reconstitution du paléo-niveau de base au Paléocène effectuée par Husson (2013) montre que celui-ci devait être situé à environ -900 m dans la zone étudiée. Or, l'épaisseur des formations carbonatées varie entre 600 et 1100 m d'épaisseur, ce qui implique une phase de karstification importante de cette zone qui a ensuite été soumise à la subsidence durant la phase d'extension oligocène.

La karstification atteint son paroxysme durant la crise messinienne, pendant laquelle une partie des réseaux du Paléocène est réactivée. L'épisode messinien, qui s'est produit il y a environ 5,96 à 5,33 millions d'années, mis en relation avec le temps de formation d'un karst gravifique, pouvant s'établir sur une durée d'à peine 10 000 à 20 000 ans (Bakalowicz, 1996), laisse supposer la possibilité d'une karstification très profonde, mais dont les conduits peuvent être à présent colmatés.

L'épisode messinien entraîne un creusement important des hydrosystèmes de surface et souterrains dont les exutoires, à cette époque, se situent bien au-delà du littoral actuel (Figure 22), à des profondeurs actuelles de -300, -500 et -1000 m comme en témoigne la surface d'érosion messinienne (Audra, et al., 2004). La remontée eustatique engendre la mise en eau totale des réseaux profonds et le comblement d'une partie d'entre eux. La source sous-marine de la Vise dans l'étang de Thau, comme la Fontaine de Vaucluse, témoignent de cette évolution. Par la suite, durant le Quaternaire, les oscillations eustatiques, dont l'amplitude peut dépasser 100 m NGF, entraînent la mise en place de nouveaux réseaux ainsi que la réactivation de réseaux messiniens.

Ainsi, une activité tectonique importante conjuguée au caractère polyphasé de la karstification ont engendré des hydrosystèmes complexes, comme celui du Lez, où l'on trouve un développement considérable des réseaux souterrains ainsi qu'une compartimentation conduisant à des fonctionnements en basses eaux ou hautes eaux très différents (Kong-A-Siou, 2011). Le jeu des failles a contribué à mettre en contact des terrains rendus perméables par la karstification, avec des terrains imperméables, ce qui a pour effet de former des barrières hydrauliques, favorisant ainsi l'émergence de sources (Lez, Lirou, Fleurette, Restinclière) et les communications souterraines parfois profondes.

#### 4.3.2. HYDRODYNAMIQUE

##### 4.3.2.1. INTRODUCTION

La connaissance du fonctionnement hydrodynamique du système repose sur l'utilisation conjointe d'approches conceptuelles sur le fonctionnement des karsts et d'études *in-situ*. Les nombreux travaux, menés sur l'hydrosystème du Lez depuis les années 70-80 (Drogue, 1974 ; Paloc, 1979 ; Karam, 1989 ; ...) jusqu'à aujourd'hui (Ladouche et al., 2014), en font un des systèmes karstiques les plus étudiés. L'ensemble de ces connaissances, étant intimement lié à l'évolution des techniques de mesures et de représentations, est susceptible d'évoluer. Par ailleurs, le système serait également susceptible d'évoluer par des forçages naturels ou anthropiques.

Les connaissances actuelles permettent de mettre en évidence le rôle prépondérant des failles sur les écoulements (horizontaux et verticaux) entre les différents compartiments identifiables. En effet, Bérard (1983) distingue 3 compartiments délimités par la faille de Corconne et celle du Pic Saint-Loup. L'aquifère est, selon le compartiment, libre ou captif. Son fonctionnement est conditionné par l'état piézométrique du système. On peut ainsi distinguer deux fonctionnements schématiques : i) hautes eaux, ii) basses eaux (Karam, 1989).

Comme l'illustre la Figure 24, l'hydrosystème du Lez est constitué d'un aquifère dit « principal » correspondant aux terrains carbonatés du Jurassique et du Berriasien. Ces formations affleurent essentiellement au niveau du Pic Saint-Loup et du Causse de Viols-le-Fort. Ils sont aussi présents à l'affleurement, de façon plus locale, au niveau du Massif de Coutach, du Bois de Mounié et du Bois de Paris. On retrouve aussi les terrains de l'aquifère principal au niveau des exutoires du système (sources du Lez, Restinclières, Fleurette).

Sur le reste du bassin, l'aquifère est sous une couverture marneuse imperméable du Crétacé et du Tertiaire. Cette couverture isole aussi les faciès de calcaires marneux de l'Hauterivien, qui constituent le Causse de l'Hortus, formant ainsi un aquifère perché qui donne naissance à des sources karstiques temporaires en période de crue. Une partie de ces eaux issues des sources temporaires va se perdre au niveau de la faille de Corconne, assurant ainsi une connectivité entre le Causse de l'Hortus et l'aquifère principal.

L'activité tectonique et sédimentaire du bassin est responsable de cette structure complexe de l'aquifère. La connectivité entre les formations ainsi que les écoulements sont conditionnés par les failles qui peuvent être des vecteurs (horizontaux et verticaux) d'écoulements, ou encore des barrières hydrauliques. Les principales entités hydrauliques du bassin (sources et pertes) sont associées à la présence de failles favorisant soit l'infiltration, soit l'émergence des eaux associée à des discordances stratigraphiques.

#### 4.1.1.1. ALIMENTATION DU SYSTEME ET EXUTOIRES TEMPORAIRES

On peut distinguer 2 types d'alimentation, sur le bassin du Lez, qui sont généralement liés à la saison et à l'état du système.

Le premier type d'alimentation correspond à une recharge « directe », par infiltration localisée ou diffuse des précipitations sur les zones d'affleurement de l'aquifère principal. Soit une surface d'environ 120 km<sup>2</sup> (Fleury et al. 2008 ; Maréchal et al., 2012). Sur cette zone, l'alimentation du karst est soumise au fonctionnement de l'épikarst, lorsqu'il est présent, qui est susceptible d'accélérer ou de différer l'infiltration. Sur la Figure 24 est situé l'aven de la Fausse-Monnaie qui constitue une ouverture en surface vers le reste du réseau souterrain. L'alimentation directe génère donc des composantes temporelles multiples que l'on cherche à identifier grâce aux traçages et à la géochimie (Bicalho, 2010).

L'autre type d'alimentation est associé aux pertes des hydrosystèmes de surface. Or, l'essentiel des cours d'eau présents sur le bassin sont temporaires. Ils sont issus : i) de la concentration du ruissellement sur des terrains imperméables et ii) de la mise en charge de sources karstiques temporaires.

Le fonctionnement de ce type d'alimentation est lié au fonctionnement saisonnier des cours d'eau et à l'état général du niveau piézométrique des différents compartiments de l'aquifère. Depuis la mise en place, en 1982, du pompage des réserves souterraines du Lez, l'état du système subit une perturbation qui tend à diminuer son niveau général. De ce fait, certaines sources d'alimentation ont été modifiées par l'exploitation de la ressource, dont l'impact sur le système sera détaillé plus loin.

Au sud du bassin, lors des épisodes pluvieux, en période de hautes eaux, les sources temporaires du Terrieu, du Yorgues et du Lirou, dont les deux premiers sont les affluents, se mettent à fonctionner. Situées en amont du Lez, celles-ci vont traverser des zones de pertes localisées notamment sur la faille de Corconne, mais aussi sur d'autres accidents de moindre amplitude.

Au nord du bassin, la mise en charge du Causse de l'Hortus génère la mise en fonction de sources karstiques comme la Foux-de-Lauret et le Brestalou-de-Claret qui se perdent en partie au niveau de la faille de Corconne.




Figure 24 : Bloc diagramme schématique du bassin de la source du Lez et de son fonctionnement hydrodynamique. Modifié d'après Paloc (1979). Version anglaise en Annexe E.



#### 4.1.1.2. CIRCULATIONS SOUTERRAINES

Le fonctionnement hydrodynamique de l'aquifère karstique du Lez est complexe du fait : i) de son alimentation qui varie selon l'état hydrique du bassin hydrogéologique, ii) d'une complexité géomorphologique, iii) du caractère anisotrope et hétérogène du karst.

Il est néanmoins possible, grâce à la connaissance accumulée, d'avoir une certaine compréhension du fonctionnement hydrodynamique (Figure 25) malgré les perturbations associées à son exploitation. En effet, l'abaissement du niveau d'eau par les pompages de la source du Lez, a un impact sur le reste de l'aquifère dont le niveau s'abaisse.

Le site expérimental du Terrieu situé en amont de la source du Lez (Figure 24) est équipé d'une vingtaine de forages permettant l'étude des écoulements au sein du karst dans une zone sensiblement fracturée (Drogue et Grillot, 1976). Les forages effectués sur ce site recoupent différentes familles de fractures dont certaines assurent une connexion au drain principal de la source du Lez. En effet, lors de la mise en marche des pompes de la station du Lez, on observe une diminution du niveau dans certains des forages du Terrieu. Ces derniers ne réagissent pas en même temps, ni avec la même dynamique à cette perturbation du fait d'une connectivité plus ou moins directe avec le drain principal de la source.

L'abaissement du niveau piézométrique associé au pompage a pour effet d'affecter le fonctionnement de trop pleins comme les sources du Lirou, de Fleurette et de Restinclières. Le pompage a donc pour effet de « court-circuiter » certains exutoires, sollicitant ainsi une zone plus importante de l'aquifère (Ladouche et al., 2014).

La Figure 24 schématise la morphologie et la dynamique de l'aquifère. On observe des zones d'affleurement de l'aquifère principal (Causse de Viols-le-Fort, massif de Coutach, ...) où celui-ci est libre. L'infiltration et la circulation dans ces zones se fait donc de façon localisée ou diffuse selon le développement de l'épikarst, Drogue (1964) a estimé un coefficient d'infiltration de 50% pour les zones d'affleurement. Dans sa partie captive l'aquifère est alimenté localement au niveau des pertes présentées précédemment.

Le développement du réseau ainsi que les écoulements souterrains, bien que difficilement caractérisables, peuvent être approchés de façon conceptuelle grâce à l'étude de la karstification (potentiel de karstification) et des marqueurs accessibles (sources, pertes, cavités, fracturation et accidents majeurs).

L'approche conceptuelle est développée et améliorée grâce aux études *in situ* tels que les traçages ou encore les essais par pompages. Le site expérimental du Terrieu permet, comme il a été décrit précédemment, d'étudier l'impact de l'exploitation de la source du Lez, il permet aussi d'étudier localement les transferts au sein du karst. En effet, Jazayeri Noushabadi et al. (2011) mettent en évidence, grâce à la température et la conductivité, une circulation préférentielle à l'intersection entre des fractures et le plan de stratification. Ces observations laissent supposer des bancs plus perméables favorables aux écoulements. Sur ce même site expérimental, les essais par pompage et le logging (Jazayeri, 2009) permettent d'étudier l'importance de la fracturation sur le développement de la karstification et sur la connectivité du réseau.

Les traçages effectués depuis des décennies (référéncés dans : Jourde et al., 2011) ainsi que le suivi piézométrique (Bicalho, 2010) ont permis d'établir les limites du bassin hydrogéologique et aussi le schéma général des circulations souterraines :

- Dans la zone située au nord-ouest du bassin du Lez (Causse de l'Hortus), l'aquifère principal est sous couverture ; il est coupé de la partie Sud-Ouest (Causse de Viols-le-Fort) par le chevauchement au niveau du Pic Saint-Loup. Les échanges souterrains entre la partie Nord-Ouest (alimentée par une partie de l'Hortus et du massif de Coutach) et la partie Est se font donc à la faveur de la faille de Corconne. Le traçage effectué peu avant la période de basses eaux dans la perte du ruisseau d'Artigues (Figure 24), réapparu après 123 jours à la source du Lez, témoigne d'une contribution étendue au nord du Causse de l'Hortus. Les injections effectuées aux pertes de Lauret et de Claret

(Figure 24) sont apparues, à des périodes différentes, à la source du Lez, respectivement 26 jours et moins de 15 jours après leur injection. Le compartiment Nord-Ouest semble donc générer des composantes temporelles variables qui sont associées aux transferts : i) jusqu'à la faille de Corconne par circulation souterraine sous le Causse de l'Hortus et en surface à partir des sources temporaires de Lauret et Claret, ii) le long de cette même faille. Le suivi piézométrique du forage de Claret Brissac, effectué dans le cadre du « projet Lez GMU », témoigne d'une connectivité au drain principal de la source du Lez, avec un niveau supérieur de 5 mètres. La piézométrie au niveau du massif de Coutach est supérieure de 20 à 40 mètres par rapport à la source du Lez, mais elles présentent des similitudes de variation.

- La zone située à l'est de la faille de Corconne jusqu'au niveau de la source du Lez est essentiellement sous couverture avec quelques affleurements de l'aquifère principal. Le forage du Triadou (Leonardi et al., 2012) témoigne d'une circulation sous pression dans les zones captives avec un niveau piézométrique situé à 150 mètres au-dessus du toit de l'aquifère. Les circulations se font à la faveur des failles nord-est sud-ouest (réseau de failles Corconne-Matelles), générées lors de l'extension Oligocène, et des failles nord-sud. La piézométrie dans cette zone est proche de celle du Lez, avec cependant un gradient nord-sud observé sur les piézomètres de Fontanès et Bois-des-Roziers. Plus au sud, les fluctuations enregistrées par les piézomètres témoignent de 2 comportements : i) en hautes eaux, le niveau de la source est plus élevé ce qui entraîne à la mise en fonction d'autres exutoires ; ii) lors du forçage anthropique en basses eaux, le rabattement associé au pompage à la source favorise le drainage de ce compartiment. Ces circulations attestent d'un drainage orienté selon l'axe nord-est sud-ouest.

Plus localement, la fracturation relevée sur le site expérimental du Terrieu révèle une famille majoritaire de fractures N150-170. Ces directions suggèrent une karstification qui permet de drainer les écoulements vers les accidents majeurs nord-est sud-ouest. Ces derniers mettent en contact, à l'affleurement, des formations aquifères avec des terrains imperméables recouvrant l'aquifère. Ces barrières hydrauliques favorisent l'émergence des sources karstiques (Lez, Restinclières, Fleurette). Des traçages effectués en période de crue sur différentes pertes du Terrieu montrent des temps de transfert de 5 à 10 jours vers la source. Les pertes sur le cours du Lirou ont des temps de transfert compris entre 1 et 2 jours ce qui suggèrent une bonne connectivité assurée par la faille à l'origine de l'émergence de la source du Lez.

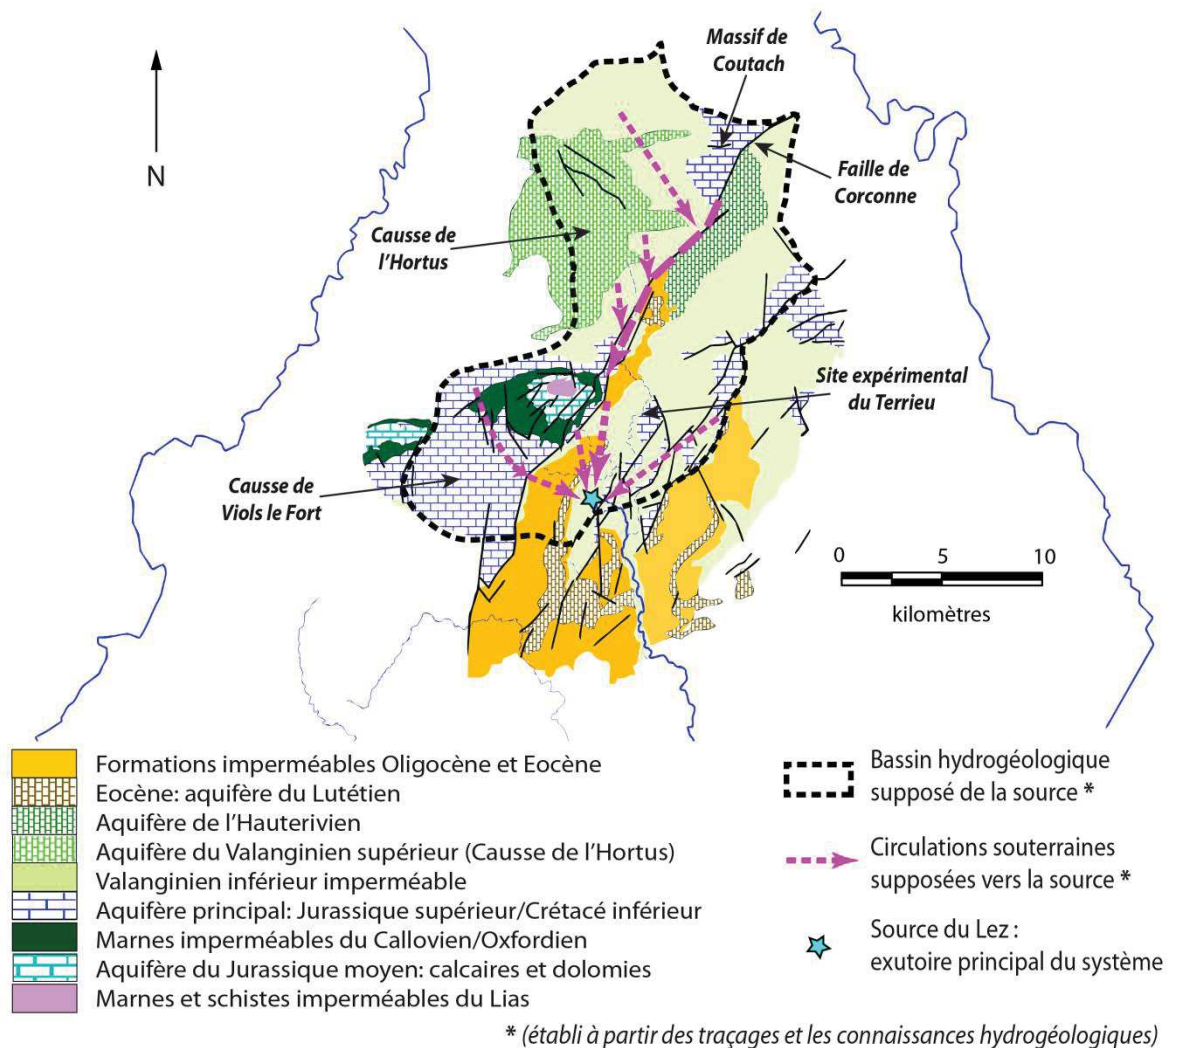


Figure 25 : Carte hydrogéologique interprétative des circulations souterraines de la source du Lez.

- La zone principale d’affleurement de l’aquifère correspond au Causse de Viols-le-Fort qui se situe hydrauliquement en amont de la source du Lez. Le piézomètre des Matelles présente des fluctuations similaires à celles de la source du Lez, avec une différence de niveau piézométrique comprise entre 20 et 40 mètres. Le fort gradient ainsi que les traçages effectués à partir de l’Aven de la Fausse-Monnaie confirment la contribution du Causse de Viols-le-Fort à l’alimentation souterraine de la source du Lez ainsi que celle du Lirou, en période de hautes eaux lorsque l’aquifère déborde par ses autres exutoires. Les traçages à partir de l’Aven de la Fausse-Monnaie permettent d’identifier un temps de transfert d’environ 27 jours (en hautes eaux) pour la contribution aux écoulements de la source du Lez.
- L’interface entre le Causse de Viols-le-Fort et la Source du Lez est marquée par le réseau de failles Matelles-Corconne. Cette zone est un lieu à la fois d’émergence (source de Fontgrand, Boulidou de Saint Jean de Cuculles, source du Lirou) et à la fois de pertes (perte du Yorgues, perte du Triadou, pertes du Lirou) comme l’illustre la Figure 24. Les traçages effectués en période de hautes eaux sur des pertes du Lirou présentent des temps de transfert, vers la source du Lez, de 1 à 2 jours. En revanche, la perte de Yorgues, tracée à une autre période, présente un temps de transfert de 58 jours. Il existe donc bien un rôle important des failles, mais les contributions des différentes zones vont être conditionnées par le développement de la karstification et le niveau piézométrique.

- Les travaux de (Caetano Bicalho et al., 2012) sur l'étude géochimique des eaux du bassin a abouti à une schéma conceptuel du fonctionnement de la source du Lez intégrant une composante d'écoulements profonds. Ce schéma conceptuel est basé sur une signature géochimique témoignant d'une circulation profonde des eaux dans les formations évaporitiques du Trias qui seraient entrainées vers la surface à la faveur des accidents majeurs.

#### 4.4. LES MODELISATIONS HYDRODYNAMIQUES DE L'HYDROSYSTEME LEZ

Dans le chapitre 1, nous avons évoqué la nécessité d'utiliser la modélisation pour améliorer la compréhension du fonctionnement hydrodynamique des karsts en estimant par exemple des paramètres, des propriétés difficilement mesurables sur le terrain. L'hydrosystème du Lez ne fait pas exception comme le confirment les nombreux modèles développés depuis les années 70.

L'objectif de cette section est de présenter un certain nombre de ces modèles, leurs objectifs, leurs fondements et leurs limites. De façon générale, on peut distinguer les approches empiriques, conceptuelles et à base physique, sans que celles-ci soient totalement incompatibles. On peut aussi distinguer les modèles en fonction de leurs objectifs, c'est-à-dire que certains visent à : i) représenter le débit ou la piézométrie sous influence des pompages de façon locale sur le site expérimental du Terrieu (Jazayeri Noushabadi, 2009) ou bien à la source dans la vasque ou dans le drain en fonction de la période étudiée, ii) identifier des fonctionnement, des processus hydrodynamiques, iii) modéliser ou prévoir les débits en période de crue (événementiel) ou en période d'étiage.

Parmi les nombreux modèles développés sur l'hydrosystème du Lez, on peut citer les modèles développés par Karam (1989) qui visent à estimer des contributions spatiales et des modes de fonctionnement du système à partir des paramètres des modèles. À l'aide d'un modèle distribué et d'un modèle stochastique Y. Karam a donc pu proposer la contribution de différents compartiments de l'aquifère en fonction du niveau piézométrique dans le drain principal.

Récemment, différents modèles ont été développés dans le cadre du « projet Lez GMU » et sont détaillés dans le rapport (Borrell Estupina et al., 2012). Les collaborations et les différents modèles rassemblés par ce projet permettent d'améliorer la compréhension du fonctionnement hydrodynamique pour une meilleure gestion de l'aquifère et des risques. Certains de ces modèles ciblent les crues en aval de la source dont la contribution aux débits observés est faible. Ces modèles ne seront pas abordés ici, seuls sont présentés ci-après ceux qui ne caractérisent que l'aquifère ou les sources.

Le logiciel Tempo, développé par le BRGM est un modèle basé sur une approche systémique qui utilise une fonction de transfert afin de simuler de façon journalière : i) le débit de débordement à la source en période de crue, ii) le niveau piézométrique au niveau du drain principal et de la matrice sous l'effet des pompages. Les résultats obtenus avec ce modèle semi-distribué (Ladouche et al., 2014) ont montré que l'aquifère n'est pas surexploité. Ce modèle utilisé avec des scénarii de changement climatique permet de simuler la piézométrie avec différents scénarios de pompages, sous contraintes.

Un autre modèle développé par le BRGM est le modèle VENSIM (Fleury et al., 2008) qui est un modèle à réservoirs qui se base sur un bilan hydrique afin de de représenter aussi bien le niveau piézométrique dans le drain principal que le débit à la source. L'avantage de ce modèle est de pouvoir simuler les crues et les étiages au pas de temps journalier. Ce dernier a été comparé au modèle par réseau de neurones de Kong A Siou (2011) et en cours de publication (Kong-A-Siou et al., 2014). Les modèles de réseaux de neurones utilisés sont des perceptrons multicouches récurrents permettant la simulation et la prévision des débits en période de crue ou encore la représentation du niveau piézométrique du drain en période sèche.

Le modèle POKA à base physique vise à représenter l'évolution du niveau dans le drain sous influence des pompages en période sèche à partir des interactions drain-matrice. L'inconvénient de ce modèle est qu'il ne

prend pas en compte les pluies et qu'il ne peut être utilisé qu'à court terme pour une certaine gamme de battement (entre 40 et 65 mNGF).

Le modèle FEFLOW (Diersch, 1998) est un modèle distribué à base physique qui vise la caractérisation du système, des conductivités hydraulique, ou encore de l'emménagement. Il a été appliqué par Mazzilli (2011) à l'hydrosystème du Lez.

Ces modèles portent globalement sur les crues, l'impact des pompages en période de basses eaux, ou encore les propriétés hydrodynamiques de l'hydrosystème. Les modèles développés dans cette thèse ont pour objectif : i) d'appréhender et de représenter la relation pluie-débit et ses différentes composantes temporelles, ii) de rendre le fonctionnement des modèles réseaux de neurones plus proches du fonctionnement du système naturel afin de rendre les paramètres des modèles exploitables pour tirer un maximum d'informations sur le fonctionnement hydrodynamique du karst.

#### 4.5. CONCLUSION

La présentation géographique et climatique du bassin du Lez a pour objectif de souligner son importance en tant que ressource pérenne exploitable. L'exploitation de l'aquifère génère un rabattement qui s'étend, au nord, jusqu'au piézomètre de Fontanès. Cette perturbation influence les circulations souterraines par une augmentation du gradient hydraulique entre le l'hydrosystème et son exutoire.

La présentation du contexte géologique, tectonique et eustatique a permis de mieux appréhender la structure du bassin et le développement de la karstification. L'échelle stratigraphique du bassin est essentiellement composée de niveaux aquifères et imperméables du Jurassique et du Crétacé. Les accidents majeurs (nord-est sud-ouest) sont responsables de la compartimentation de l'aquifère et des discordances stratigraphiques à l'origine des principales sources karstiques (Lez, Lirou, etc.). Les blocs, délimités par ces accidents majeurs, sont affectés par une importante fracturation de direction globalement nord-sud.

La compartimentation de l'aquifère permet de distinguer des zones où l'aquifère est libre (Causse de Viol-le-Fort) et d'autres où il est captif sous des niveaux imperméables, dont certains sont eux-mêmes surmontés par des aquifères perchés (Causse de l'Hortus).

Les aquifères perchés ont un fonctionnement saisonnier, c'est-à-dire qu'en période de hautes eaux, ils génèrent l'émergence de sources karstiques temporaires dont les eaux vont se perdre à la faveur des accidents majeurs tels que la faille de Corconne.

La circulation, sous pression, des eaux dans les zones captives de l'aquifère peut être responsable de l'émergence de sources karstiques au contact avec les accidents tectoniques majeurs.

Les parties libres de l'aquifère, où celui-ci affleure, sont des zones de recharge directe, qui présentent des fluctuations similaires du niveau piézométrique avec un gradient hydraulique marqué (supérieur à 20 mètres). Ces zones ont donc une importante contribution aux écoulements à la source du Lez.

Il ressort de ce chapitre que le fonctionnement de l'hydrosystème karstique du Lez est complexe du fait des variabilités saisonnières : i) de l'alimentation du système, ii) de la connectivité. En effet, les perturbations anthropiques montrent que le rabattement artificiel du niveau piézométrique à la source tend à solliciter les réserves, parfois profondes, du système. La connectivité du réseau est susceptible de diminuer en période d'étiage du fait d'un abaissement du niveau dans l'ensemble des compartiments de l'aquifère. Ce rabattement a une influence parfois prononcée sur les crues de reprise automnales (Borrell Estupina et al., 2014).

Finalement, ce chapitre permet de mieux appréhender la complexité du fonctionnement hydrodynamique de la source du Lez, et surtout, l'origine des différentes composantes temporelles présentes dans le signal de débit du Lez. Les composantes temporelles de grande période, lorsqu'elles sont identifiables, sont susceptibles de fournir une explication sur la pérennité du débit à la source malgré l'importance de la saison sèche.

Dans la suite nous présenterons comment le modèle à réseaux de neurones permet d'améliorer la prise en compte de ces contributions à moyen et à long terme.



# 5. ETUDE DU FONCTIONNEMENT HYDRODYNAMIQUE DE LA SOURCE DU LEZ, EN REGIME NATUREL : AMELIORER LES MODELES POUR EN EXTRAIRE DE L'INFORMATION.

## 5.1. INTRODUCTION

L'hydrosystème karstique du Lez est caractérisé par un développement du réseau souterrain complexe qui collecte les eaux des différents compartiments du système (chapitre 4). La caractérisation du fonctionnement hydrodynamique de ce système s'appuie sur des schémas conceptuels et des connaissances collectées *in situ* (traçages, piézométrie, température...). Or, l'acquisition de données relatives au fonctionnement hydrodynamique du karst et l'analyse détaillée des processus qui contrôlent l'écoulement sont souvent difficiles à mettre en place. L'objectif de ce travail est donc d'utiliser les méthodes globales d'analyse et de modélisation pour approfondir ces éléments.

L'approche systémique, telle qu'elle a été présentée dans les chapitres 2 et 3, permet d'étudier et de modéliser le système à partir de ses séries d'entrée et de sortie. Ce type de méthode permet, dans une certaine mesure, de s'affranchir des processus physiques. Néanmoins, comme le montrent les travaux de Johannet et al. (2008) et Kong-A-Siou et al. (2013), il est possible d'utiliser la connaissance disponible pour contraindre le modèle afin d'en extraire de l'information. L'objectif est donc de construire, à partir de l'analyse du système, un modèle dont les paramètres soient susceptibles d'être exploités. Pour ce faire, il est nécessaire d'étudier la construction et le comportement du modèle ainsi que la prise en compte des entrées, comme nous l'avons vu au chapitre 3.

L'un des points encore actifs en recherche scientifique de l'apprentissage statistique est la construction du modèle et la sélection des variables (ici la définition des fenêtres temporelles des variables). La validation croisée, présentée au chapitre 3, est la méthode utilisée dans les travaux récents (Artigue et al., 2012 ; Kong-A-Siou et al., 2013) pour sélectionner le nombre de neurones cachés et la taille des fenêtres temporelles des entrées. Cette méthode de sélection est consommatrice de temps de calcul et ne s'appuie pas sur la connaissance du système. Les travaux proposés ici visent à mettre en place une méthode, alternative à la validation croisée, qui utilise les informations des analyses systémiques linéaires pour sélectionner l'historique de pluie nécessaire pour alimenter les différents modèles utilisés.

Le premier point concerne donc l'application de l'analyse des signaux et du système pour mieux appréhender le fonctionnement hydrodynamique du karst. L'exploitation approfondie de ces analyses conduit à identifier des processus empiriques qui interviennent à des échelles temporelles variées. Les informations obtenues sur le fonctionnement du système et sur les processus sous-jacents à la *réponse impulsionnelle* sont susceptibles d'être utilisées pour contraindre le modèle et lui apporter des informations pertinentes en entrée afin de faciliter sa construction et d'améliorer ses résultats.



Afin de mieux comprendre l'enjeu correspondant à la sélection des modèles et leurs conséquences sur la sortie calculée, la méthode dite « classique » de sélection des variables par la validation croisée est utilisée afin de fournir un objet de comparaison.

Les travaux présentés ensuite correspondent à l'utilisation de la *Taverlette* qui est la méthode de décomposition des données, présentée au chapitre 3, dont le choix des composantes temporelles est obtenu grâce aux analyses du système. Les composantes ainsi générées sont utilisées en entrée des modèles récurrents et non-récurrents afin de mieux appréhender le comportement des modèles, ainsi que l'importance des différentes variables d'entrée.

La poursuite des pistes obtenues se fait au travers des travaux publiés dans les Presses de Mines (Conférence E3D). Cette étude porte sur la contrainte du modèle récurrent par les informations issues des analyses linéaires. Ce chapitre de livre, ainsi que les compléments apportés par la suite, montrent qu'il est possible de contraindre le modèle et d'améliorer ses performances pour obtenir des informations relatives à la relation pluie-débit.

Les travaux suivants portent sur cette analyse approfondie des poids affectés par les modèles aux entrées. Cette analyse permet d'obtenir une représentation de la *réponse impulsionnelle* comparable à celle obtenue avec le corrélogramme.

Le dernier point abordé dans ce manuscrit concerne l'utilisation de l'assimilation de données pour améliorer le modèle, et pour effectuer une estimation de la pluie efficace ou encore pour combler des lacunes dans les données d'entrée.

## 5.2. DESCRIPTION STATISTIQUE ET ANALYSES LINEAIRES DE LA RELATION PLUIE-DEBIT

### 5.2.1. ANALYSE DES DONNEES

#### 5.2.1.1. PRESENTATION DES DONNEES

Pour cette étude, le choix du système à étudier s'est porté sur l'hydrosystème du Lez en régime naturel. C'est-à-dire sur une période pour laquelle l'exploitation du système se fait de manière passive, par gravité, donc sans perturbations majeures comme nous l'avons évoqué au chapitre 4. La période retenue se situe donc entre la date de réfection du seuil à la source (novembre 1949) et le début de l'exploitation dans la vasque de la source du Lez (janvier 1968). Les données enregistrées durant cette période, de 1950 à 1967, ne sont pas de très bonne qualité comme en témoignent les effets de quantification observables sur la série de débit (Figure 37). De plus, l'échantillonnage au pas de temps journalier ne permet pas d'observer les fluctuations les plus rapides du débit. La série de débit a été obtenue par transformation des hauteurs d'eau au seuil grâce à la courbe de tarage (annexe A) établie par Thiéry et al. (1983).

Les travaux de Johannet et al. (2008) sur la modélisation entrée-sortie par apprentissage statistique ont montré une certaine souplesse du modèle vis-à-vis de l'évapotranspiration potentielle (ETP) comme entrée. Cette flexibilité du modèle neuronal permet de s'affranchir des questions relatives à l'utilisation d'une variable d'évapotranspiration à estimer, ce qui est aussi observé pour les modèles à réservoir (Oudin et al., 2005 ; Andréassian et al., 2004). Les valeurs d'évapotranspiration utilisées suivent ainsi une gaussienne normalisée à 0,9, de période annuelle, dont le maximum est au 30 juin. L'utilisation de la variable d'ETP gaussienne comme entrée sera discutée plus tard lors de l'étude de la prise en compte des entrées par le modèle. Cette variable d'ETP correspond à une information saisonnière extrêmement simplifiée.

## 5.2.1.2. ANALYSE DU SIGNAL DE PLUIE

### 5.2.1.2.1. VALIDATION DE L'UTILISATION DU PLUVIOMETRE DE VALFLAUNES

Les pluies utilisées comme entrées du système karstique proviennent du pluviomètre de Valflaunès (Figure 37) qui est situé au centre du bassin. Afin de valider l'utilisation de ce pluviomètre, il est possible d'utiliser les données issues des pluviomètres installés plus récemment. L'application de la corrélation croisée entre le pluviomètre de Valflaunès et d'autres pluviomètres du bassin permet d'étudier la pertinence de la mesure utilisée. L'application des polygones de Thiessen par Kong A Siou (2011) montre que le pluviomètre de Valflaunès est le seul à contribuer aux trois zones principales (Nord-Ouest ; Sud-Ouest ; Est). De plus, les résultats des corrélations (Tableau 2), entre les pluies enregistrées à Valflaunès et les pluies enregistrées en d'autres points du bassin, montrent que : i) le maximum de corrélation est atteint systématiquement pour un décalage temporel nul, ii) les maximums de corrélation sont élevés. Notons bien que cette observation est limitée à des données échantillonnées de manière journalière ; ce constat serait vraisemblablement à modifier avec un échantillonnage horaire.

Tableau 2 : Corrélation croisée entre les données du pluviomètre de Valflaunès et les données issues de d'autres pluviomètres sur le bassin pour la période 1996-2005 (échantillonnage journalier).

|  | St Martin de Londres | Prades le Lez | Pompignan | Montarnaud |
|--|----------------------|---------------|-----------|------------|
| Maximum de corrélation                   | 0,84                 | 0,90          | 0,85      | 0,79       |
| Retard du maximum de corrélation (jours) | 0                    | 0             | 0         | 0          |

L'utilisation du pluviomètre de Valflaunès apparaît donc comme adéquate malgré une variabilité temporelle et spatiale des pluies dans la région. En effet, comme il a été présenté au chapitre 4, il existe un gradient entre les pluies enregistrées près du littoral et celles enregistrées près des reliefs, ce qui explique la valeur la plus faible du pic de corrélation obtenue avec le pluviomètre de Montarnaud qui se situe hors du bassin, au sud-ouest. Les orages méditerranéens sont aussi responsables des écarts qu'il peut y avoir localement. C'est-à-dire que ce type d'orage génère des précipitations intenses et localisées qui peuvent n'affecter qu'une partie du bassin. Il existe donc des événements qui n'ont pas été enregistrés par le pluviomètre de Valflaunès et qui ont pourtant contribué au débit à la source. Cette absence de données spatiales de pluie, sur la période étudiée, peut dans certains cas constituer une limite à l'étude de la relation pluie-débit. Une méthode sera proposée à la fin du chapitre pour tenter de combler ce type de lacunes.

### 5.2.1.2.2. DESCRIPTION STATISTIQUE DE LA CHRONIQUE DE PLUIE

En région méditerranéenne, la répartition des pluies journalières au cours de l'année (Figure 26) entraîne i) un stress hydrique important durant la saison sèche, ii) des épisodes de crues rapides à l'automne et au printemps.

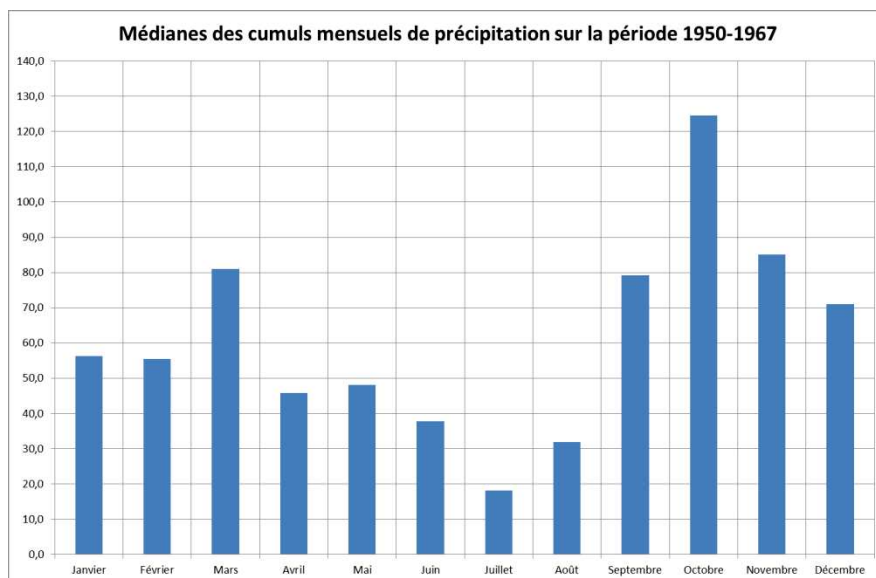


Figure 26 : Valeurs médianes des cumuls de pluie mensuels sur la période 1950-1967.

L'essentiel des précipitations a, en effet, lieu à l'automne et au printemps comme on peut le voir sur la Figure 26 qui concerne la période traitée dans ce travail. On constate sur cette figure que les mois les plus pluvieux sont : mars, septembre, octobre, novembre. La saison sèche concerne essentiellement les mois de juillet et d'août.

Tableau 3 : Principaux descripteurs statistiques de la série chronologique de pluie journalière (en mm) pour la période 1950 à 1967. Le cumul et le maximum correspondent à la moyenne des valeurs annuelles.

| Moyenne (mm) | Médiane (mm) | Maximum (mm) | Cumul (mm) | Kurtosis | Skewness |
|--------------|--------------|--------------|------------|----------|----------|
| 2,4          | 0,0          | 88,5         | 887        | 62       | 7        |

Si l'on s'intéresse à la distribution des pluies sur cette période (Tableau 3), on observe que celle-ci est très asymétrique (skewness=7) et très « pointue » (kurtosis=62) avec des valeurs centrales (moyenne et médiane) proches ou égales à 0. La valeur élevée du kurtosis traduit une distribution pour laquelle l'essentiel des valeurs sont regroupées autour des valeurs médianes, donc de 0 dans ce cas. La valeur positive du skewness montre que la distribution est étirée par la présence de quelques valeurs de pluie très élevées. Ces observations traduisent bien les caractéristiques climatiques du bassin présentées au chapitre 4 : le faible nombre de jours de pluie et les fortes et rares intensités observables.

À l'échelle annuelle (Tableau 4), la variabilité des indicateurs statistiques illustre l'importance des variations interannuelles des précipitations. De plus, les différences observées entre les moyennes et les médianes témoignent de la rareté et de l'intensité des pluies. En effet, cette différence s'explique par des valeurs élevées dont l'effectif est nettement plus réduit que celui des valeurs nulles ou très faibles, la moyenne est donc tirée vers le haut alors que la médiane est égale à 0.

Cette inégale répartition des précipitations au cours de l'année et de la période est caractéristique des régions méditerranéennes. Ces conditions ont un impact sur la pérennité des ressources en eau, mais aussi sur les phénomènes de crue. Finalement, la variabilité de l'entrée principale de l'hydrosystème a un impact sur son état et donc sur son fonctionnement, ce qui accentue la non-linéarité de la relation entrée-sortie.

Tableau 4 : Principaux descripteurs statistiques de la distribution annuelle des pluies journalières sur la période 1950-1967.

|      | Maximum<br>(mm) | Moyenne<br>(mm) | Médiane<br>(mm) | Cumul<br>(mm) | kurtosis | skewness |
|------|-----------------|-----------------|-----------------|---------------|----------|----------|
| 1950 | 55              | 1,3             | 0,0             | 457           | 45,9     | 6,4      |
| 1951 | 75              | 2,2             | 0,0             | 796           | 33,9     | 5,4      |
| 1952 | 83              | 1,7             | 0,0             | 610           | 59,2     | 7,0      |
| 1953 | 91              | 2,7             | 0,0             | 987           | 38,3     | 5,9      |
| 1954 | 78              | 2,2             | 0,0             | 820           | 34,6     | 5,4      |
| 1955 | 74              | 2,8             | 0,0             | 1008          | 25,9     | 4,9      |
| 1956 | 81              | 2,5             | 0,0             | 918           | 26,9     | 4,8      |
| 1957 | 56              | 2,1             | 0,0             | 777           | 20,7     | 4,4      |
| 1958 | 175             | 1,9             | 0,0             | 705           | 158,7    | 11,4     |
| 1959 | 62              | 3,0             | 0,0             | 1094          | 16,2     | 3,9      |
| 1960 | 80              | 2,7             | 0,0             | 994           | 31,0     | 5,1      |
| 1961 | 100             | 2,1             | 0,0             | 769           | 57,5     | 6,9      |
| 1962 | 70              | 2,6             | 0,0             | 937           | 23,1     | 4,6      |
| 1963 | 141             | 4,2             | 0,0             | 1538          | 43,9     | 5,8      |
| 1964 | 151             | 3,5             | 0,0             | 1270          | 59,8     | 6,6      |
| 1965 | 85              | 2,5             | 0,0             | 920           | 45,8     | 6,3      |
| 1966 | 68              | 2,0             | 0,0             | 747           | 33,3     | 5,4      |
| 1967 | 69              | 1,9             | 0,0             | 620           | 39,8     | 5,8      |

#### 5.2.1.2.3. CORRELOGRAMME ET SPECTRE SIMPLES DU SIGNAL DE PLUIE

Le calcul du corrélogramme simple du signal de pluie permet d'étudier la corrélation temporelle du signal. Or, on observe sur la Figure 27a une chute brutale du coefficient de corrélation dès le premier jour de décalage, au-delà, les valeurs oscillent autour de 0 (Figure 27b). Le corrélogramme suggère donc que, sur la période étudiée, il n'existe pas de corrélation entre les pluies ni à court ni à long terme.




Figure 27 : Corrélogramme simple de la série de pluie journalière pour la période 1950-1967. a)  $k \in [0;750]$  b)  $k \in [0;50]$ .

L'étude du spectre simple du signal de pluie, en échelle logarithmique représenté Figure 28, permet d'étudier le type de bruit correspondant. La troncature la plus faible sert à visualiser une courbe « lissée » qui ne laisse apparaître que les périodicités majeures sans représenter les fréquences les plus basses et la variabilité interannuelle, tandis que la troncature de 1500 jours est utilisée pour visualiser les basses fréquences. On constate que la pente est quasi nulle ce qui correspond à un bruit blanc, c'est-à-dire la réalisation d'un processus aléatoire (Hausdorff et al., 1996). On peut toutefois noter un pic de faible amplitude à la fréquence  $0,00267 \text{ j}^{-1}$  qui correspond globalement à une périodicité annuelle (374 j) très peu marquée et non observée sur le corrélogramme.

L'indépendance temporelle, illustrée par le corrélogramme, et le caractère quasi aléatoire de la pluie, illustré par le spectre, sont des caractéristiques importantes pour l'analyse du système qui sera effectuée plus tard.

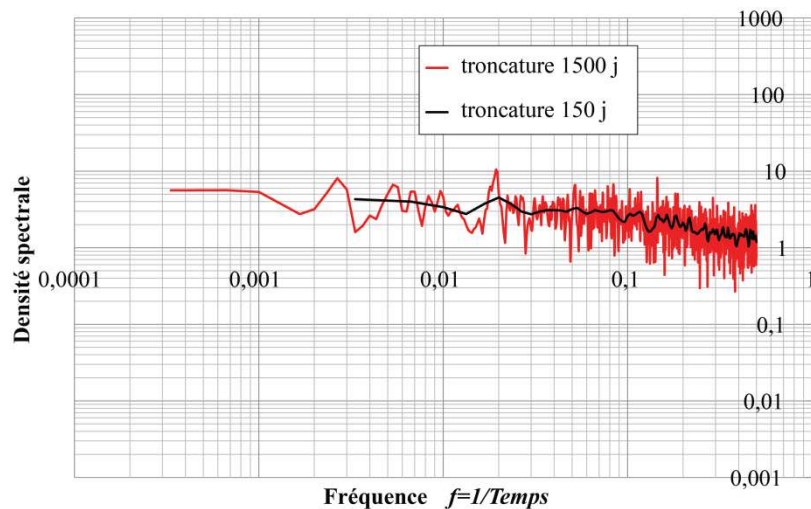


Figure 28 : Spectre simple du signal de pluie (échelles logarithmiques) pour la période 1950-1967. La courbe rouge correspond à la transformée de Fourier de l'autocorrélation ayant subi l'application d'une troncature de 1500 jours et la courbe noire correspond à la transformée de Fourier de l'autocorrélation ayant subi une troncature de 150 jours.

### 5.2.1.3. ANALYSE DU SIGNAL DE DEBIT

Le signal de débit étudié ici provient de données anciennes qui ont visiblement été échantillonnées, quantifiées avec un pas trop large (ce qui est possible compte-tenu de l'époque des mesures), ou dont d'éventuelles lacunes pourraient avoir été comblées. Les données originales et la méthode d'échantillonnage utilisée n'ont pu être obtenues. Ainsi, les « plateaux » que l'on peut rencontrer sur plusieurs jours successifs ne pourront être corrigés. Ces plateaux suggèrent la perte d'une information sur les variations à court terme qui est probablement due à la manière d'enregistrer l'information, c'est-à-dire que pour économiser sur le stockage, certains opérateurs n'enregistrent des données que lorsque la valeur a suffisamment varié. Ces défauts de la

série de débit semblent toutefois acceptables vis-à-vis de l'erreur généralement associée à la mesure du débit et à l'utilisation de la courbe de tarage.

### 5.2.1.3.1. DESCRIPTION STATISTIQUE DE LA CHRONIQUE DE DEBIT

Dans le Tableau 5, on constate que le débit moyen sur la période est de l'ordre de  $2\text{m}^3/\text{s}$  avec une variabilité interannuelle comprise entre  $1,2$  et  $3,6\text{m}^3/\text{s}$  (Tableau 6). Les débits moyens journaliers maximums atteints lors des crues oscillent entre  $4,6$  et  $11,3\text{m}^3/\text{s}$  en fonction des années, soit un débit maximum moyen de  $8\text{m}^3/\text{s}$ . Ces valeurs contrastent avec les débits moyens et les débits minimums, ce qui atteste d'importantes variations de la dynamique de la source du Lez en fonction des saisons et des années.

Tableau 5 : Principaux indicateurs statistiques de la série chronologique de débit journalier (en  $\text{m}^3/\text{s}$ ) pour la période 1950 à 1967. La moyenne, la médiane, le minimum et le maximum correspondent aux moyennes des valeurs annuelles.

| Moyenne<br>( $\text{m}^3/\text{s}$ ) | Médiane<br>( $\text{m}^3/\text{s}$ ) | Minimum<br>( $\text{m}^3/\text{s}$ ) | Maximum<br>( $\text{m}^3/\text{s}$ ) | Kurtosis | Skewness |
|--------------------------------------|--------------------------------------|--------------------------------------|--------------------------------------|----------|----------|
| 1,95                                 | 1,47                                 | 0,20                                 | 7,99                                 | 1,06     | 1,20     |

Les valeurs maximales observées sur la période 1950-1967 sont inférieures à celles présentées dans Kong A Siou (2011) pour la période 1997-2005, alors que durant cette dernière période des prélèvements importants sont effectués pour l'alimentation en eau potable.

De façon générale, on constate que la distribution des débits est nettement moins dispersée que celle des pluies. Cette observation est confirmée par les valeurs du skewness (1,20) et du kurtosis (1,06) sur la période complète. En effet, ces valeurs sont nettement inférieures aux valeurs obtenues pour la pluie ( $s=7$  et  $k=62$ ). Cette observation laisse d'ores et déjà supposer le rôle de filtre que joue l'hydrosystème sur ses entrées en réduisant leur dispersion. Au niveau annuel, on constate même que la distribution des débits peut s'approcher d'une distribution gaussienne pour laquelle le kurtosis et le skewness valent 0. De plus, l'écart, toujours positif, observé entre la moyenne et la médiane atteste d'une certaine asymétrie de la distribution où quelques valeurs élevées tirent la moyenne vers le haut.

Du point de vue de la répartition mensuelle (Figure 29), on observe que la saisonnalité est bien marquée avec toutefois des extremums variables selon les années. En effet, on remarque avec les minimums que l'étiage concernent essentiellement les mois de juillet à octobre. Or, on voit aussi que le mois d'octobre est particulièrement sujet aux crues comme en témoignent les valeurs de la moyenne et du maximum mensuel moyen. Les crues majeures ont lieu majoritairement à l'automne et au printemps. Si l'on compare ce résultat aux cumuls mensuels (Figure 26), on constate que les cumuls de précipitations sont nettement plus importants en automne, ce qui illustre le rôle de tampon du karst pour les crues automnales. En effet, le maintien du débit de base à la source (niveau de débordement de  $64,91\text{mNGF}$ ) mobilise les ressources du bassin et abaisse son niveau piézométrique. Les pluies d'automne vont donc d'abord réalimenter le réseau souterrain avant de contribuer à l'augmentation du débit à la source.

Tableau 6 : Principaux indicateurs statistiques de la distribution du débit annuel sur la période 1950-1967.

|      | Minimum<br>( $\text{m}^3/\text{s}$ ) | Maximum<br>( $\text{m}^3/\text{s}$ ) | Moyenne<br>( $\text{m}^3/\text{s}$ ) | Médiane<br>( $\text{m}^3/\text{s}$ ) | Kurtosis | Skewness |
|------|--------------------------------------|--------------------------------------|--------------------------------------|--------------------------------------|----------|----------|
| 1950 | 0,125                                | 4,6                                  | 1,2                                  | 0,7                                  | 1,4      | 1,5      |
| 1951 | 0,596                                | 8,0                                  | 2,4                                  | 1,8                                  | 0,6      | 1,1      |
| 1952 | 0,117                                | 9,0                                  | 1,6                                  | 1,3                                  | 4,2      | 1,8      |

|      |       |      |     |     |      |     |
|------|-------|------|-----|-----|------|-----|
| 1953 | 0,062 | 8,5  | 1,5 | 0,7 | 2,0  | 1,7 |
| 1954 | 0,188 | 7,1  | 2,1 | 1,8 | 0,4  | 1,0 |
| 1955 | 0,176 | 9,6  | 2,3 | 1,8 | 1,2  | 1,2 |
| 1956 | 0,197 | 8,0  | 1,6 | 0,9 | 3,2  | 1,8 |
| 1957 | 0,158 | 7,1  | 2,3 | 1,8 | -0,7 | 0,7 |
| 1958 | 0,077 | 5,7  | 1,3 | 0,8 | 2,9  | 1,7 |
| 1959 | 0,312 | 7,5  | 2,0 | 1,5 | 1,4  | 1,3 |
| 1960 | 0,092 | 7,5  | 1,7 | 1,3 | 4,0  | 1,9 |
| 1961 | 0,067 | 6,6  | 1,2 | 0,7 | 2,1  | 1,6 |
| 1962 | 0,077 | 8,0  | 2,3 | 1,8 | 0,1  | 0,7 |
| 1963 | 0,929 | 10,1 | 3,6 | 3,2 | -0,1 | 0,7 |
| 1964 | 0,279 | 9,6  | 3,0 | 2,7 | 0,0  | 0,7 |
| 1965 | 0,036 | 7,5  | 2,1 | 1,5 | -0,6 | 0,6 |
| 1966 | 0,067 | 8,0  | 1,9 | 1,5 | 1,1  | 1,1 |
| 1967 | 0,040 | 11,3 | 1,3 | 0,4 | 4,6  | 2,2 |

De plus, comme il a été présenté au chapitre 4, le fonctionnement hydrodynamique supposé de la source du Lez implique qu'une part de l'alimentation est issue des pertes de cours d'eaux temporaires. Or, à la sortie de la saison sèche, ces sources n'ont pas encore repris leur fonctionnement, ce n'est que pendant les périodes de crues que ces dernières sont alimentés. Ces effets de seuils expliquent une partie de la non-linéarité de la réponse du système face à une entrée pseudo-aléatoire. C'est-à-dire que selon l'état du système, celui-ci ne réagit pas de la même façon, il est donc important de pouvoir estimer cet état.




Figure 29 : Moyennes sur la période 1950-1967 des descripteurs statistiques mensuels du débit.

L'analyse des débits classés, effectuée par Conroux (2007) sur la période 1949-1968, souligne différents comportements supposés du système correspondant à : i) l'alimentation du débit de base par la vidange des

réserves pour les débits inférieurs à  $0,8\text{m}^3/\text{s}$ , ii) la mise en charge progressive du système et l'évacuation par d'autres exutoires pour les débits supérieurs à  $0,8\text{m}^3/\text{s}$ . Les ruptures de pentes observées au-delà de  $0,8\text{m}^3/\text{s}$  pourraient correspondre à la mise en fonctionnement de sources karstiques temporaires (Lirou, Restinclières, etc.).

#### 5.2.1.3.2. CORRELOGRAMME ET SPECTRE SIMPLE DU SIGNAL DE DEBIT

Selon la méthodologie développée par Mangin (1981), la corrélation simple du débit permet de définir l'effet mémoire qui correspond à la durée pour laquelle le signal devient statistiquement indépendant de ses réalisations futures. Cette durée correspond au décalage entre le signal et lui-même observé lorsque la corrélation atteint la valeur de 0,2. Cette valeur est obtenue selon certaines hypothèses liées à la distribution statistique des signaux pour un intervalle de confiance de 5%. L'effet mémoire, obtenu pour le débit du Lez à la source, sur la période étudiée (Figure 30), est de 64 jours, ce qui signifie qu'il existe une dépendance entre le débit observé à un instant  $t$  et les deux mois qui précèdent. D'après l'analyse de plusieurs hydrosystèmes karstiques par Mangin (1998), le système du Lez est très inerte, ce qui signifie qu'il existe des réserves qui vont réduire la pente du tarissement.

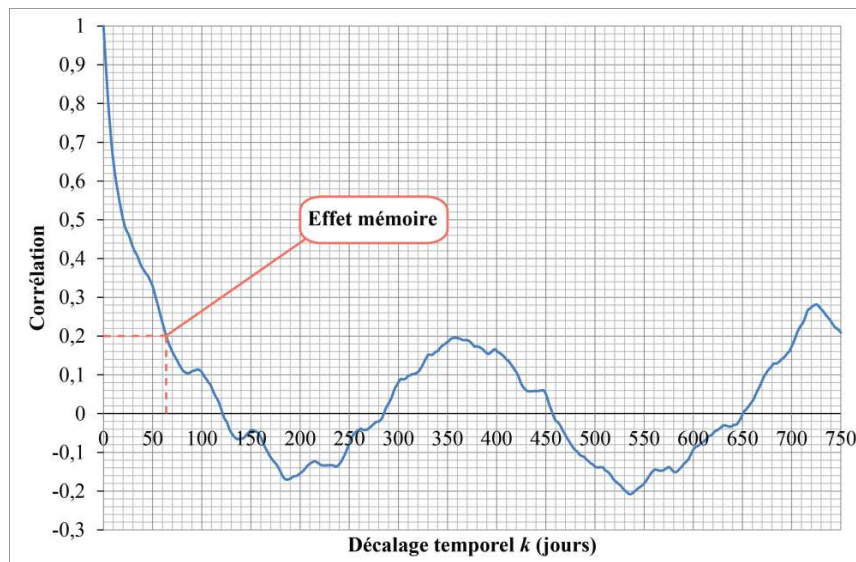


Figure 30 : Corrélogramme simple du signal de débit de la source du Lez sur la période 1950-1967.

Sur la Figure 30, on constate une remontée du corrélogramme autour de 365 jours et de 730 jours. Cela signifie qu'il existe une périodicité annuelle des débits que l'on ne retrouve pas au niveau du corrélogramme de la pluie. Cette cyclicité est donc essentiellement induite par le système lui-même, c'est-à-dire que le karst introduit une cyclicité annuelle lorsqu'il filtre les pluies, due en grande partie à d'autres forçages (Évapotranspiration, ...).



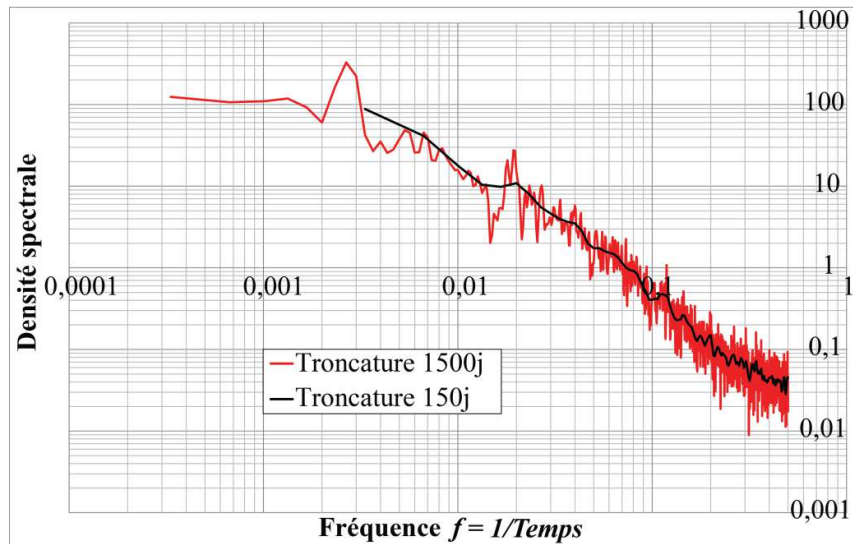


Figure 31 : Densité spectrale ou spectre simple du signal de débit à la source du Lez (échelles logarithmiques) pour la période 1950-1967. La courbe rouge correspond à l'application d'une troncature de 1500 jours et la courbe noire correspond à une troncature de 150 jours.

Le spectre du débit, tracé en coordonnées logarithmiques pour deux troncatures différentes (Figure 31), présente une pente générale importante et négative, sauf pour les plus basses fréquences. En termes d'étude du bruit, la pente du spectre pour les moyennes et hautes fréquences est globalement proche de -2 malgré quelques légères ruptures. Or, une pente négative signifie que le système est intégrateur. La Figure 31 montre donc que le signal de débit correspond à une intégration des moyennes et hautes fréquences du signal de pluie.

Les oscillations qui différencient le spectre pour les deux troncatures (150 et 1500 jours) sont *a priori* liées la variabilité annuelle qui n'est pas prise en compte lorsque l'on calcule l'autocorrélation avec une troncature de 150 jours.

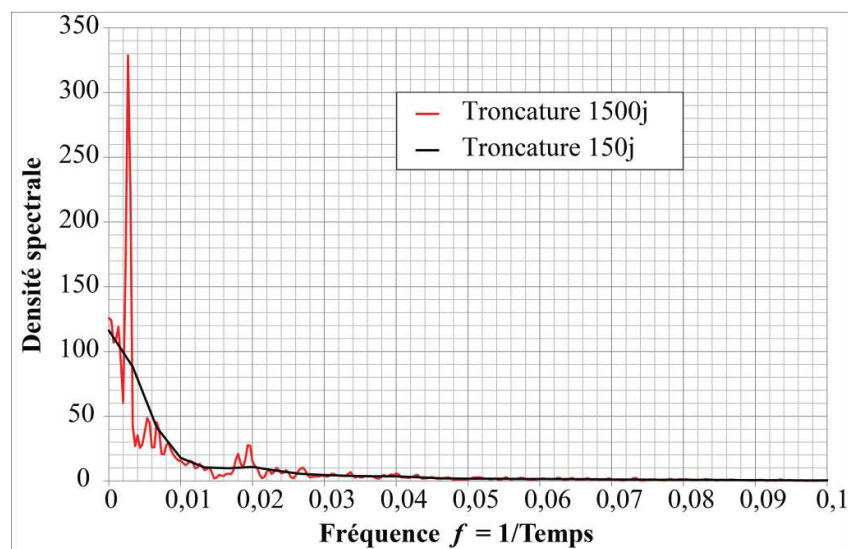


Figure 32 : Densité spectrale ou spectre simple du signal de débit à la source du Lez pour la période 1950-1967. La courbe rouge correspond à l'application d'une troncature de 1500 jours et la courbe noire correspond à une troncature de 150 jours.

La représentation graphique du spectre (Figure 32) laisse apparaître différents pics essentiellement observables sur la courbe rouge qui correspond à la plus grande des deux troncatures. Ces différents pics sont assimilables à des phénomènes périodiques relatifs au fonctionnement du système. On note un pic à la fréquence  $0,0026 \text{ j}^{-1}$  qui correspond à une périodicité annuelle. On note aussi un pic proche de  $0,02 \text{ j}^{-1}$  qui correspond à une périodicité d'une cinquantaine de jours. L'étude du spectre permet aussi d'extraire deux paramètres définis par

Mangin (1984) : i) le temps de régulation correspondant à la moitié de la valeur du spectre de puissance à la fréquence 0, ii) la fréquence de coupure ( $F_{cm}$ )<sup>5</sup> qui représente la fréquence à partir de laquelle le spectre devient négligeable (inférieur à 1).

Tableau 7 : Situation du Lez dans la classification des karsts. D'après Mangin, 1984.

| Type         | Effet mémoire   | Fréquence de coupure ( $F_{cm}$ ) | Temps de régulation |
|--------------|-----------------|-----------------------------------|---------------------|
| Aliou        | 5 jours         | 0,3                               | 10 à 15 jours       |
| Baget        | 10 à 15 jours   | 0,2                               | 20 à 30 jours       |
| Fontestorbes | 50 à 60 jours   | 0,1                               | 50 jours            |
| <b>Lez</b>   | <b>64 jours</b> | <b>0,08</b>                       | <b>60 jours</b>     |
| Torcal       | 70 jours        | 0,05                              | 70 jours            |

D'après la classification des karsts de Mangin (1984) (Tableau 7), l'hydrosystème du Lez se situe dans la catégorie des aquifères qui effectuent un important filtrage de la pluie en entrée. Dans le cas du Lez, ce filtrage peut être expliqué par : i) la karstification, ii) la morphologie compartimentée du système ii) l'alimentation différée par les pertes issues des sources temporaires de karsts perchés.

### 5.2.2. ANALYSE DU SYSTEME

L'analyse des signaux effectuée précédemment permet d'appréhender la structure, la dépendance temporelle ainsi que la périodicité de chacun. Néanmoins, l'analyse du système nécessite une analyse croisée des signaux afin de mieux caractériser leurs relations.

Dans un premier temps, l'étude de la forme des distributions (Figure 33) permet de mettre en évidence le filtrage effectué par le système. En effet, on observe que les distributions très pointues et asymétriques de pluies sont transformées par le système en distributions qui tendent à s'approcher de distributions gaussiennes ( $k=0$  et  $s=0$ ). Cette observation signifie que les valeurs extrêmes de pluie sont amorties et que la dispersion des valeurs est nettement diminuée. Ceci est confirmé par le point en marge des valeurs obtenues pour la pluie qui correspond à l'année 1958 et qu'on ne retrouve pas en marge dans le cas du débit. En effet, l'année 1958 est celle qui a le cumul journalier de pluie le plus important alors que les débits maximums de l'année 1958 sont près de deux fois inférieurs à ceux observés sur l'ensemble de la période 1950-1967.

<sup>5</sup> Le terme « fréquence de coupure » utilisé par A. Mangin ne correspond pas à la fréquence de coupure du filtre définie en traitement du signal. La fréquence de coupure selon A. Mangin sera notée  $F_{cm}$ , et la fréquence de coupure d'un filtre sera notée  $F_c$ . Les valeurs obtenues seront présentées lors de l'analyse du système, dans la section suivante.

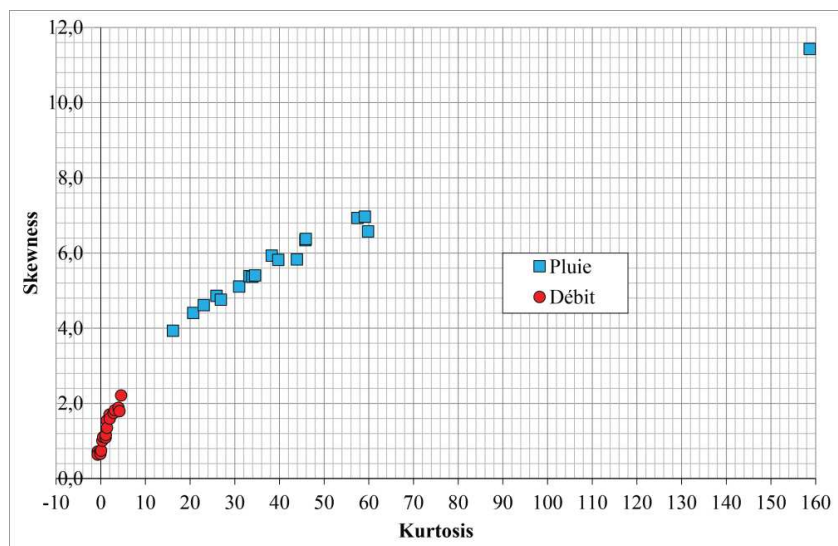


Figure 33 : Coefficients d'aplatissement (kurtosis) et d'asymétrie (skewness) annuels des séries journalières de pluie (en bleu) et de débit (en rouge) pour la période 1950-1967.

### 5.2.2.1. ANALYSE DE LA FONCTION DE TRANSFERT

La fonction de transfert telle qu'elle a été définie au chapitre 2 illustre, dans le domaine fréquentiel, la transformation opérée par un système linéaire. Sa représentation en échelles logarithmiques (Figure 34a) permet dans un premier temps d'observer que les basses fréquences ne sont pas, ou très peu, modifiées par le système. Le karst a donc un rôle de filtre passe-bas dont la fréquence de coupure ( $F_c$ ) vaut environ  $0,0036 \text{ j}^{-1}$  (277 j). La fréquence de coupure du filtre passe-bas est la fréquence au-delà de laquelle toutes les fréquences supérieures sont atténuées par le système. Étant donné que les fréquences sont l'inverse du temps ( $T = 1/f$ ), on peut conclure que le système effectue un filtrage des entrées sur 277 jours ( $=1/0,0036$ ) environ. Cela signifie que la réponse du système à une impulsion en entrée va être atténuée et répartie sur plus de 200 jours.

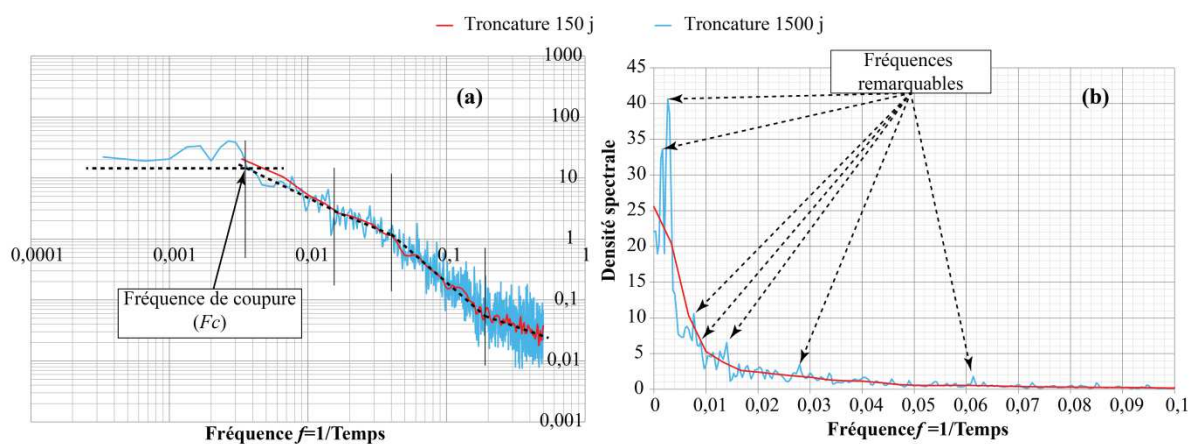


Figure 34 : Fonction de transfert, en échelles logarithmiques (a) et linéaires (b), de l'hydrosystème karstique du Lez sur la période 1950-1967.

Sur la Figure 34a on observe aussi qu'il existe des ruptures de pentes soulignées par les droites en pointillés noirs. Nous interprétons ces ruptures comme autant de transitions d'un comportement vers un autre ; ces ruptures correspondraient à différentes opérations effectuées par le système. Ces dernières sont probablement dues aux différentes circulations (de la surface vers la zone saturée et au sein de la zone saturée) présentées dans le chapitre précédent.

Tableau 8 : Périodicités identifiées à partir de pics observés sur la fonction de transfert de la période 1950-1967.

|                          |        |        |         |        |       |       |       |       |       |       |      |
|--------------------------|--------|--------|---------|--------|-------|-------|-------|-------|-------|-------|------|
| Fréquence<br>$f(j^{-1})$ | 0,0013 | 0,0016 | 0,00267 | 0,0076 | 0,009 | 0,014 | 0,028 | 0,061 | 0,085 | 0,138 | 0,38 |
| Périodicité<br>(jours)   | 769    | 625    | 375     | 132    | 111   | 71    | 36    | 16    | 12    | 7     | 3    |

L'étude de la densité spectrale représentée sans échelle logarithmique (Figure 34b) permet aussi d'observer des pics *a priori* associés à des périodicités qui sont strictement induites par le système ou des entrées non mesurées. Certaines périodicités correspondant aux pics observés sur la densité spectrale ont été reportées dans le Tableau 8 où on peut retrouver la périodicité annuelle. Les autres valeurs, présentées dans le Tableau 8, peuvent être mises en relation avec les composantes temporelles identifiées par traçages (Tableau 9). Il faut garder à l'esprit que les traçages correspondent aux transferts de masse et de pression, or les temps de transfert référencés dans le Tableau 9 correspondent à l'apparition du traceur, sans tenir compte du taux de restitution ni des conditions hydrodynamiques lors de l'injection. Ces temps de transfert sont donc utilisés à titre indicatifs pour montrer la diversité des échelles temporelles.

Tableau 9 : Temps de transferts vers la source du Lez identifiés par traçages (référencés dans « projet Lez GMU »).

| Traçage                      | Temps de transfert vers le Lez (jours) |
|------------------------------|--|
| Perte du ruisseau d'Artigues | 123                                    |
| Perte de Yorgues             | 58                                     |
| Aven de la Fausse Monnaie    | 27                                     |
| Perte de Lauret              | 26                                     |
| Perte de Claret              | 15                                     |
| Pertes du Terrieu            | 5 à 10                                 |
| Lirou                        | 1 à 2                                  |

À l'observation des fréquences associées aux pics et des fréquences associées aux temps de transferts (Tableau 8, Tableau 9), on peut noter une convergence entre les valeurs. Ces observations semblent donc confirmer la pertinence de l'analyse de la fonction de transfert pour l'étude des composantes fréquentielles du fonctionnement hydrodynamique. Ces résultats confortent ainsi la complémentarité des études *in situ* et de l'analyse systémique pour l'étude des hydrosystèmes karstiques.

#### 5.2.2.2. ANALYSE DE LA REPONSE IMPULSIONNELLE

L'analyse de la réponse impulsionnelle effectuée à partir du corrélogramme croisé (Figure 35) permet dans un premier temps de vérifier la causalité de la relation pluie-débit. On constate effectivement que pour les abscisses inférieures à zéro le corrélogramme est quasi nul, au-delà il augmente rapidement illustrant ainsi la réponse du système à une impulsion.

Le maximum de corrélation, atteint au bout de 3 jours, renseigne sur le temps de réponse du système. La décroissance rapide du corrélogramme entraîne un passage sous le seuil théorique de 0,2 après 9 jours. Or, comme il a été suggéré au chapitre 2, du fait que le système est non linéaire, il est possible de poursuivre

l'exploitation du corrélogramme croisé au-delà de ce seuil statistique. De plus, le caractère pérenne de la source du Lez, en dépit des étés secs, nécessite la présence de composantes temporelles à grande période afin d'alimenter le débit de base. L'analyse du corrélogramme croisé peut donc se poursuivre au-delà de la valeur de 9 jours, associée au seuil de 0,2.

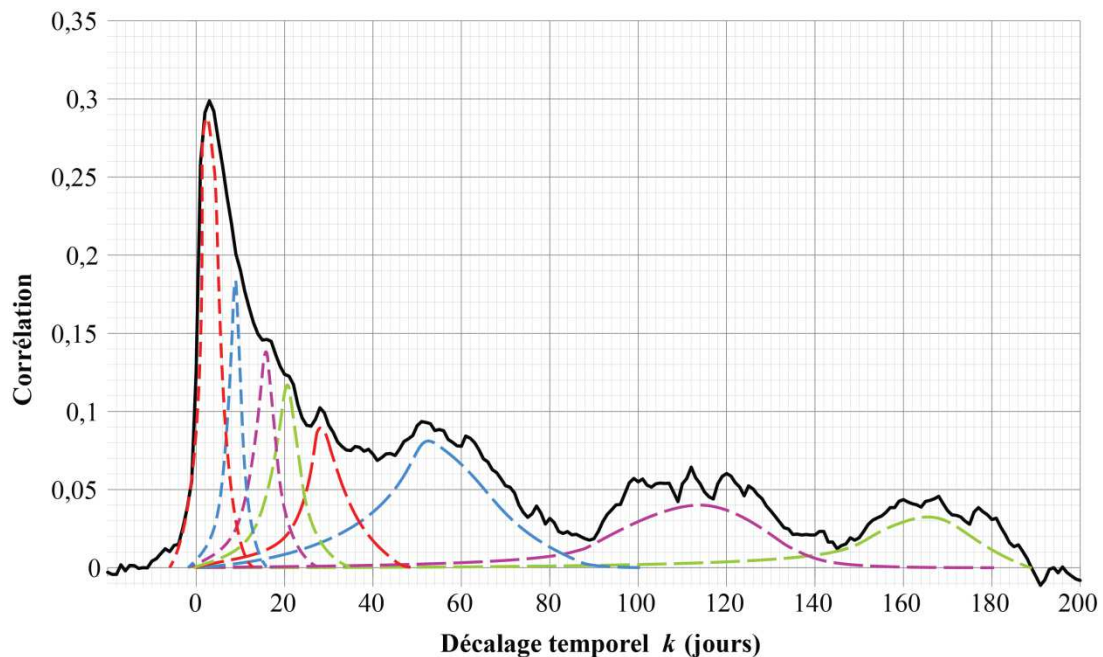


Figure 35 : Corrélogramme croisé pluie-débit (courbe noire) sur la période 1950-1967. Les courbes en pointillés correspondent aux processus sous-jacents supposés.

Sur la Figure 35, à partir de 9 jours, on commence à observer des ruptures de pentes, par la suite, on peut même observer des pics, de base plus ou moins large. Les oscillations du corrélogramme croisé suggèrent ainsi qu'il n'y a pas une réponse unique, avec un pic suivi d'une décroissance, mais plusieurs réponses qui interviennent à des échelles de temps et avec des amplitudes différentes. Cette hypothèse semble cohérente avec la complexité hydrodynamique de l'hydrosystème du Lez au sein duquel différents compartiments vont contribuer. Nous proposons de décomposer la réponse impulsionnelle en une somme de plusieurs réponses associées à autant de processus comme illustré de façon empirique sur la Figure 35.

Les ordres de grandeur des processus supposés, déduits du corrélogramme croisé sont cohérents avec les informations apportées par la fonction de transfert et les traçages.

L'analyse du système permet ainsi de suggérer que l'information disponible en dessous du seuil statistique de corrélation de 0,2 peut être exploitable et permet d'estimer une relation entrée-sortie, jusqu'à au moins 150 jours.

### 5.2.3. CONCLUSIONS SUR L'ANALYSE DES SIGNAUX ET DU SYSTEME

La complexité des hydrosystèmes karstiques et les difficultés d'investigation *in situ* de leur fonctionnement hydrodynamique font de l'approche systémique un outil essentiel pour l'étude des karsts. Cette approche conceptuelle doit néanmoins se baser sur la connaissance que l'on possède sur le fonctionnement de l'hydrosystème.

En s'appuyant sur une étude préalable des signaux, l'analyse du système a permis de mettre en évidence certaines propriétés hydrodynamiques du karst. En effet, l'analyse des distributions des séries de pluie et de débit a souligné le filtrage induit par le système qui fait tendre la distribution des débits vers une distribution gaussienne en amortissant les valeurs extrêmes ; ce fonctionnement est qualifié d' «intégrateur».

L'analyse de la fonction de transfert a montré que le karst effectue un filtrage passe-bas des pluies avec une fréquence de coupure équivalente à environ 280 jours.

L'analyse corrélatoire croisée a permis d'obtenir une représentation de la *réponse impulsionnelle* du système qui, dans un premier temps, a confirmé la relation de causalité entre la pluie et le débit. Elle a ensuite été utilisée pour identifier, de façon empirique, des processus qui constituent cette *réponse impulsionnelle*.

L'hypothèse est donc que les informations apportées par le corrélogramme croisé en dessous du seuil 0,2 ne doivent pas être négligées. En effet, ces informations à plus long terme sont *a priori* indispensables pour expliquer la pérennité de la source du Lez malgré des étés très secs.

La suite de ce mémoire aborde différentes utilisations des informations obtenues ici pour contraindre les modèles par réseaux de neurones afin de les rendre plus représentatifs en vue d'une exploitation approfondie qui conduit à l'acquisition de connaissances sur le fonctionnement hydrodynamique du système.

### 5.3. SELECTION D'UN MODELE RECURRENT PAR VALIDATION CROISEE

Le choix du modèle récurrent qui est *a priori* moins performant que le modèle non-récurrent est motivé par le fait que ce modèle n'est pas alimenté par des observations de sa sortie en cours d'utilisation. De ce fait, il peut être utilisé pour des études visant à étudier l'impact du changement climatique ou encore pour compléter des lacunes dans les données de débit ou corriger ces dernières lorsqu'elles sont de mauvaise qualité. De plus, l'absence d'informations mesurées entraîne le modèle à mieux prendre en compte ses entrées exogènes pour estimer la sortie. Ce point est particulièrement intéressant pour un modèle qu'on cherche à rendre représentatif de la réalité afin d'en extraire des informations.

Cette section illustre la construction d'un modèle récurrent de façon que nous appellerons « classique » (Johannet et al., 2012b), c'est-à-dire en utilisant la validation croisée pour sélectionner les variables d'entrée : l'historique de pluie et de débit (ou « l'ordre » du modèle).

#### 5.3.1. DONNEES UTILISEES

Les variables utilisées pour modéliser le fonctionnement hydrodynamique quasi-naturel du Lez sont : i) les pluies journalières enregistrées à Valflaunès, ii) l'évapotranspiration potentielle (ETP), représentée par une gaussienne avec une amplitude maximale en été, iii) les débits journaliers à la source obtenus à partir de la conversion des hauteurs d'eau dans la vasque (courbe de tarage en annexe A). La base de données s'étend sur la période 1950-1967 qui correspond à la période où l'exploitation passive a un impact faible sur la relation entrée-sortie.

Le découpage de la base de données se fait en 3 ensembles, comme il a été présenté au chapitre 3 :

- Ensemble d'apprentissage : 1950-1958 et 1962-1967
- Ensemble d'arrêt : 1959
- Ensemble de test : 1960-1961

Pour l'ensemble de test, le choix s'est porté sur deux années consécutives contenant des crues automnales et printanières ainsi qu'une période sèche bien marquée. L'objectif est de confronter le modèle aux principales conditions qu'il est susceptible de rencontrer. L'ensemble d'arrêt, 1959, est une année marquée par un printemps arrosé.

#### 5.3.2. ARCHITECTURE ET SELECTION DU MODELE

Le modèle élaboré ici est un perceptron multicouche récurrent tel que présenté au chapitre 3, ses entrées sont la pluie ( $P$ ), l'ETP et le débit simulé ( $Q_{sim}$ ) par le modèle aux temps précédents. Il sera noté par la suite modèle ANN et nous servira de référence pour étudier d'autres modèles.

L'ordre de grandeur des fenêtres d'entrée a été déterminé à partir du nombre de jours maximum pour lequel les signaux de pluie et de débit sont linéairement corrélés comme proposé dans Kong A Siou et al. (2011), c'est-à-dire jusqu'au seuil 0,2, soit 9 jours (Figure 35). La validation croisée est ensuite utilisée pour déterminer la meilleure fenêtre sur une plage entre 1 et 15 jours qui encadre la valeur de 9 jours obtenue précédemment.

La fenêtre associée à chaque variable est sélectionnée à son tour tandis que les autres sont fixées. Le nombre de neurones dans la couche cachée est sélectionné en dernier également avec la validation croisée pour un nombre de neurones compris entre 1 et 10.

Le critère de Nash présenté au chapitre 3 est utilisé pour évaluer le modèle durant la phase de sélection. Les résultats relatifs à l'architecture du modèle, sa complexité et ses performances sont rassemblés dans le Tableau 10. On constate que le modèle possède 38 paramètres, ceci serait important pour un modèle hydrologique à réservoir par exemple, mais ce nombre est faible pour un modèle neuronal. Rappelons que le modèle neuronal utilise ses paramètres pour définir l'ensemble de la fonction réalisée, alors qu'un modèle hydrologique qui dispose déjà du type de fonctionnalité voit uniquement ses paramètres ajustés par la mesure ou par un calage. Ainsi, la complexité du modèle est faible et la taille des fenêtres temporelles des variables d'entrée est réduite.

Les valeurs du score de Nash égales en validation croisée et en test attestent d'une performance, certes moyenne mais stable du modèle en apprentissage comme en test.


**Tableau 10 : Architecture, complexité et performances du modèle sélectionné par validation croisée.**

| Complexité          |                              |                           | Performances               |                         |           |
|---------------------|------------------------------|---------------------------|----------------------------|-------------------------|-----------|
| Variable            | Taille de la fenêtre (jours) | Nombre de neurones cachés | Nombre total de paramètres | Nash validation croisée | Nash test |
| <i>Pluie</i>        | 5                            |                           |                            |                         |           |
| <i>ETP</i>          | 5                            | 2                         | 38                         | 0,68                    | 0,68      |
| <i>Débit simulé</i> | 8                            |                           |                            |                         |           |

### 5.3.3. DISCUSSION DES RESULTATS

L'évaluation des performances du modèle ne se limite pas au critère de Nash (Tableau 10), elle fait appel à l'étude graphique : i) des hydrogrammes observés et simulés pour les ensembles de test, ii) de la réponse impulsionnelle et de la fonction de transfert des systèmes naturel et simulé sur l'ensemble de la période (1950-1967). L'intérêt de rassembler les résultats d'apprentissage, d'arrêt et de test pour l'analyse est de pouvoir évaluer les performances à court et long terme à partir des analyses corrélatoires et spectrales. C'est-à-dire qu'il n'est pas possible d'étudier les basses fréquences sur seulement deux années puisque la troncature  $m$  doit être au maximum le tiers de l'effectif total.

Les hydrogrammes des débits observés et simulés (Figure 36a) présentent la sortie du modèle sur l'ensemble de test (1960-1961). On constate que la période de basses eaux de l'année 1961 n'est pas bien simulée par le modèle. En effet, après avoir sous-estimé les crues d'hiver, le modèle surestime les basses eaux ainsi que les deux premières crues d'automne.



**Figure 36 : Illustration des performances, sur l'ensemble de test (1960-1961), du modèle sélectionné par validation croisée. a) Précipitations et hydrogrammes observé (en noir) et simulé (en rouge). b) Corrélogrammes croisés pluie/débit (observé et simulé). c) Fonctions de transfert pluie/débit (observé et simulé) en échelles logarithmiques pour une troncature 1500 jours. Les figures b) et c) ont été établies à partir des séries complètes (ensembles d'apprentissage, d'arrêt et de test).**

Si on s'intéresse aux corrélogrammes croisés entre la pluie et les débits observés et simulés (Figure 36b), on observe que la réponse impulsionnelle générée par le modèle est surestimée jusqu'à un décalage de 50 jours après quoi elle devient inférieure à la réponse impulsionnelle issue des observations. Le modèle semble donc surestimer la contribution rapide au détriment des contributions plus lentes. Le corrélogramme croisé pluie/débit simulé présente un pic élevé dont la durée (avant la rupture observée à 5 jours dans la phase de décroissance du pic) est la même que l'historique de la fenêtre de pluie en entrée du modèle. On constate aussi que la crue du mois d'avril 1960, réponse à une pluie au profil impulsionnel (Figure 36a), est très proche de la réponse impulsionnelle (Figure 36b) tant pour l'observé que le simulé. C'est-à-dire que dans le cas du débit simulé, on observe une surestimation du pic par rapport à l'observé, celle-ci étant suivie d'une rupture de pente bien marquée qui est suivie par une surestimation du débit simulé lors de la décrue. Or, on constate que les corrélogrammes croisés pluie-débit simulé et pluie-débit observé présentent la même tendance que celle décrite dans le cas de la crue d'avril 1960. On peut donc conclure que l'analyse corrélatrice croisée apporte un éclairage complémentaire à l'évaluation des performances d'un modèle par rapport aux seuls examens de la réponse et calculs de critères de performances.

L'étude de la fonction de transfert (Figure 36c) montre que le modèle ne retranscrit pas ou très peu les périodicités induites par le système naturel. En effet, on voit nettement que la fonction de transfert du modèle ne présente que de faibles oscillations, excepté pour la périodicité annuelle qui est bien représentée. On constate aussi une coupure dans les hautes fréquences à environ  $0,2 \text{ j}^{-1}$  soit 5 jours ce qui correspond à la taille de la fenêtre de pluie en entrée du modèle.

### 5.3.4. CONCLUSIONS SUR LE MODELE ANN

Au vu des résultats obtenus avec le modèle ANN, il paraît clair que l'information utilisée en entrée ne permet pas de représenter correctement le fonctionnement hydrodynamique de l'hydrosystème du Lez (surestimation de la majorité des pics, de la décrue et de l'étiage). Plusieurs hypothèses sont susceptibles d'expliquer ces résultats : i) une mauvaise prise en compte des entrées par le modèle, ii) historique des pluies trop court pour



permettre de représenter les processus retardés de la réponse impulsionnelle présentés dans l'analyse du système, iii) une spécialisation du modèle due à l'ensemble d'arrêt dont la corrélation croisée est présentée en annexe B.

L'objectif étant d'avoir un modèle représentatif de tous les fonctionnements du système, il est intéressant d'exploiter les deux premières pistes autant que d'éliminer la troisième. La première démarche sera d'aider le modèle à prendre en compte les composantes basses fréquences de précipitation. Pour cela nous proposons de décomposer le signal de pluie afin d'apporter indépendamment différentes composantes temporelles sous forme de signaux distincts. L'étude du poids affecté, par le modèle, aux différentes composantes sera susceptible de renseigner sur la prise en compte des différentes variables ainsi que sur l'historique de pluie nécessaire à l'alimentation d'un modèle statistique représentatif du système naturel.

La seconde démarche sera d'utiliser les enseignements tirés de la démarche précédente afin de contraindre le modèle ANN pour le rendre plus représentatif du fonctionnement physique du système.

## 5.4. DECOMPOSITION DU SIGNAL D'ENTREE EN COMPOSANTES TEMPORELLES POUR IDENTIFIER LES DIFFERENTS PROCESSUS SOUS-JACENTS.

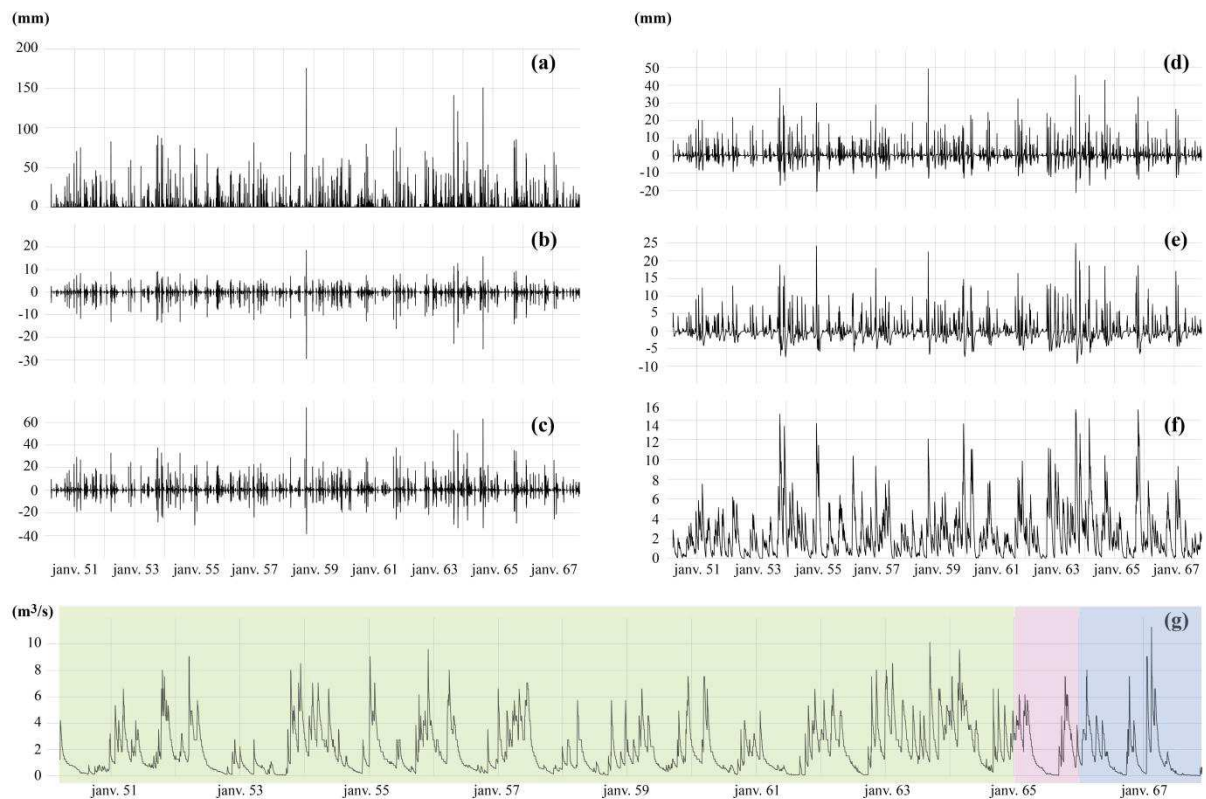
La décomposition en composantes temporelles du signal peut être utilisée pour analyser et modéliser la relation pluie débit. Inspirée de la décomposition en ondelettes orthogonales, la méthode appliquée ici vise à isoler différentes composantes temporelles du signal en fonction des processus auxquels elles sont supposées contribuer. Le signal de pluie est donc décomposé afin que le modèle reçoive des informations sur la contribution basse fréquence de la pluie. La méthodologie d'extraction de la connaissance développée par Kong A Siou et al. (2013) sera utilisée pour étudier les contributions des différentes composantes temporelles. Afin de mieux appréhender le fonctionnement des modèles par réseau de neurones, les modèles récurrents et non-récurrents vont être alimentés par les composantes de pluie. La comparaison devrait permettre de mieux interpréter le comportement du modèle récurrent. Ces travaux ont fait l'objet d'un poster à l'AGU Fall Meeting 2013 (San Francisco) dont le résumé est en Annexe D.

### 5.4.1. DECOMPOSITION MULTIREOLUTION PAR FILTRAGE PASSE-BANDE DU SIGNAL DE PLUIE

La décomposition *Taverlette* décrite au chapitre 2 est donc appliquée au signal de pluie sur la période 1950-1967. Les périodes de filtrages ont été choisies à partir de l'étude de la réponse impulsionnelle et des supposés processus sous-jacents. Or, l'échelle fréquemment utilisée en décomposition multirésolution est l'échelle dyadique ( $2^n$ ) (Labat et al., 2000), ici, afin de cibler les échelles temporelles pour qu'elles correspondent au cycle annuel, l'échelle proposée est ( $2,673^n$ ) quand  $\alpha=6$  la composante temporelle vaut 365 jours ce qui est intéressant pour l'étude des systèmes hydrologiques du fait de leur pseudo-périodicité annuelle. Dans ce travail,  $\alpha$  sera compris entre 0 et 4 pour des composantes temporelles de 1, 2, 7, 19 et 51 jours.


La variable d'évapotranspiration utilisée est, comme précédemment, une gaussienne de période annuelle dont le maximum est atteint au mois de juillet. Cette variable ne prétend pas représenter le phénomène d'évapotranspiration réelle ou potentielle, mais a plutôt pour fonction d'indiquer au modèle neuronal que le comportement qu'il doit identifier est différent en fonction des périodes de l'année. Le fait de n'être pas contraint à appliquer une information ayant un sens physique et une quantification réaliste au modèle, est un des avantages, pas suffisamment avancés, de sa double capacité d'apprentissage et de boîte noire.

Les séries présentées dans la Figure 37 correspondent aux composantes temporelles obtenues à partir de la série de pluie avec la *Taverlette*. On voit que les différentes composantes présentent des oscillations d'amplitudes et de fréquences variables. Ces différences s'expliquent par la sélectivité des filtres utilisés lors de l'application de la *Taverlette*. On voit en effet sur la Figure 39 que chaque composante a une bande de fréquence spécifique amplifiée lors de la décomposition.



**Figure 37 : Séries (période 1950-1967) de pluie à Valflaunès (a) ; de débit à la source (g) ; et les composantes temporelles de pluie : (b) = 1 jour ; (c) = 2 jours ; (d) = 7 jours ; (e) = 19 jours ; (f) = 51 jours. Les plages de couleur (g) correspondent au découpage, pour la modélisation, des ensembles d'apprentissage (vert), d'arrêt (violet) et de test (bleu).**

Il faut noter qu'il existe des similitudes entre l'hydrogramme et la composante de pluie filtrée à 51 jours (Figure 37f ;  $C_{51}$ ). La Figure 38, où les 2 signaux hydrogramme et  $C_{51}$  ont été centrés réduits afin de les rendre visuellement plus comparables, confirme que l'hydrosystème effectue un filtrage passe-bas. En effet, on observe une évolution commune des deux signaux sur l'ensemble de la période, avec toutefois des écarts dûs à la complexité et la non-linéarité de la relation pluie débit avec ses phases de stockage-déstockage. De plus, comme on le voit sur la Figure 39, le filtrage passe-bas de la pluie pour la période 51 jours a une fonction de transfert qui ressemble de manière frappante au filtrage opéré par l'hydrosystème sur son entrée de pluie. Cette composante contient donc l'information sur le fonctionnement général, mais pas sur la variabilité relative aux phénomènes périodiques à plus petite échelle.



**Figure 38 : Signaux centrés réduits (adimensionnels) du débit observé et de la composante 51 jours ( $C_{51}$ ).**

Les autres composantes contiennent en effet l'information restante qui est une information relative aux hautes fréquences, donc aux processus à plus court terme.

Un des intérêts de cette méthode est que les bandes de fréquences isolées par la décomposition couvrent globalement les principales variations de pentes de la fonction de transfert de l'hydrosystème (Figure 34a).

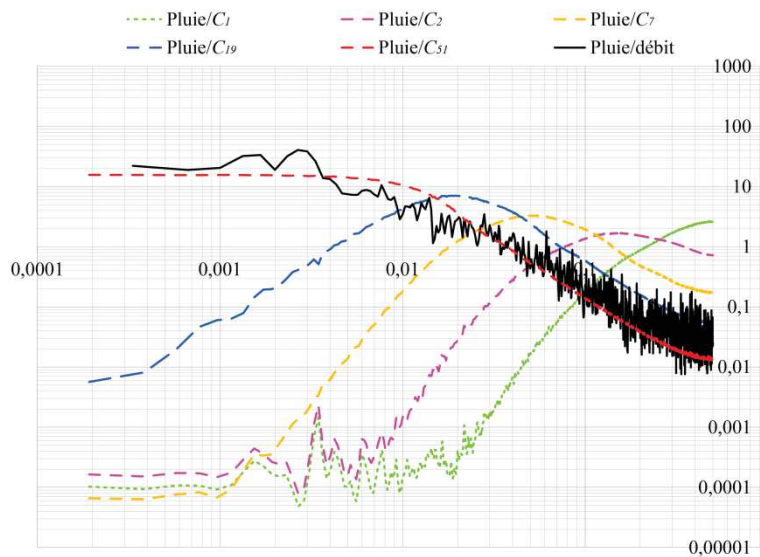


Figure 39 : Fonctions de transfert pluie/composantes de pluie (en pointillés) et pluie/débit (en trait plein).

À partir de ces signaux de pluie décomposés selon les « bandes » supposées représenter les processus sous-jacents de l'hydrosystème, nous allons maintenant réaliser un modèle neuronal pour examiner l'importance que le modèle donne à chacune d'entre elles.

#### 5.4.2. ARCHITECTURE DES MODELES RECURRENTS ET NON-RECURRENTS PRENANT EN COMPTE LES COMPOSANTES TEMPORELLES A DIFFERENTES ECHELLES

Du fait de la décomposition, le découpage des chroniques en sous-ensembles s'est fait de façon chronologique (Figure 37g) afin de ne pas générer de discontinuité dans l'ensemble d'apprentissage, condition nécessaire au calcul de la décomposition multirésolution ou par *Taverlette*.

- Ensemble d'apprentissage : 1950-1964
- Ensemble d'arrêt : 1965
- Ensemble de test : 1966-1967




Figure 40 : Représentation schématique de l'architecture du modèle par réseaux de neurones développé pour être alimenté par des composantes de pluie ( $C_1$  à  $C_{51}$ ). Chaque fenêtre d'entrée exogène est reliée à un neurone linéaire qui est relié à la couche cachée, elle-même reliée au neurone de sortie. Les paramètres ( $w$ ) en rouges sont utilisés pour le calcul de la contribution totale de l'entrée  $u_i$ .

L'architecture utilisée est fondée sur le perceptron multicouche mais elle comporte en entrée les différentes composantes temporelles précédemment identifiées. Pour les modèles récurrents et non-récurrents (Figure 40), le nombre d'entrées exogènes (composantes de pluie et évapotranspiration potentielle) et la taille de leurs fenêtres temporelles ont été ajustés.

En effet, après une étude de sensibilité des entrées nécessaire pour des raisons de temps de calcul, la taille des fenêtres temporelles de toutes les variables a été fixée à 16 jours. Le nombre important d'entrées génère une explosion du nombre de paramètres si celles-ci sont directement reliées à la couche cachée. De ce fait, chaque variable voit ses 16 valeurs reliées à un neurone linéaire intermédiaire. Cette étape permet de réduire considérablement le nombre total de paramètres (Tableau 11). Sans l'utilisation de neurones intermédiaires, le nombre total de paramètres passerait de 153 à 291 pour le modèle non-récurrent et de 234 à 582 pour le modèle récurrent, soit près du double de paramètres pour les deux modèles. Notons que du fait du caractère intégrateur de la transformation de la pluie en débit, l'introduction des neurones intermédiaires effectuant uniquement des additions n'handicape pas, *a priori*, la bonne représentation du processus de transformation de la pluie en débit.

Le Tableau 11 souligne aussi l'impact de l'évolution du nombre de neurones de la couche cachée. On constate en effet qu'en doublant le nombre de neurones de la couche cachée, on voit le nombre de paramètres, et donc la complexité du modèle, considérablement augmenter.

Les neurones intermédiaires sont des neurones linéaires, ils sont reliés aux neurones non-linéaires (sigmoïdes) de la couche cachée qui sont eux même reliés au neurone de sortie, lui aussi avec une sigmoïde, qui assure une fonction de type « seuil »  $[0,1]$  dérivable, évitant ainsi de calculer des valeurs négatives en sortie.

**Tableau 11 : Taille des fenêtres temporelles, ordre et nombre de paramètres obtenus pour les modèles non-récurrent et récurrent.**

|  | <b>Modèle<br/>non-récurrent</b> | <b>Modèle<br/>récurrent</b> |
|--|---------------------------------|-----------------------------|
| $C_1$  | 16                              | 16                          |
| $C_2$  | 16                              | 16                          |
| $C_7$  | 16                              | 16                          |
| $C_{19}$   | 16                              | 16                          |
| $C_{51}$   | 16                              | 16                          |
| $E_{TP}$   | 16                              | 16                          |
| <b>Débit<br/>(mesuré ou calculé)</b>                         | 16                              | 16                          |
| <b>Neurones dans la couche<br/>cachée (<math>N_c</math>)</b> | 3                               | 6                           |
| <b>Nombre total de paramètres</b>                            | 153                             | 234                         |

### 5.4.3. EXPLOITATION DES RESULTATS

Les deux modèles construits pour cette étude n'ont pas vu la taille de leurs fenêtres d'entrée optimisée, seul le nombre de neurones de la couche cachée ( $N_c$ ) a été sélectionné par validation croisée. Les résultats présentés correspondent aux moyennes obtenues pour 100 initialisations différentes de chacun des modèles. En effet, le

calcul de la contribution des entrées nécessite différentes initialisations du modèle pour calculer les valeurs médianes des paramètres ( $w$ ) (Figure 40).

#### 5.4.3.1. PERFORMANCES DES MODELES

L'analyse des performances par le critère de Nash sur l'ensemble de test (Tableau 12) confirme une meilleure capacité du modèle non-récurrent à représenter le fonctionnement hydrodynamique du système.

Tableau 12 : Scores de Nash moyens (100 initialisations) obtenus sur l'ensemble de test pour les modèles non-récurrent et récurrent.

|           | Modèle non-récurrent | Modèle récurrent |
|-----------|----------------------|------------------|
| Nash Test | 0,93                 | 0,80             |

En effet, l'étude des hydrogrammes (Figure 41) montre que le modèle non-récurrent représente très bien l'état général de l'hydrogramme ainsi que les pics de crues. En revanche, on constate que le modèle récurrent est capable de représenter l'état global du système mais pas les pics de crue.

On observe aussi que l'absence d'information d'état mesurée en entrée du modèle récurrent ne permet pas à celui-ci de reproduire la première crue de la série de test.

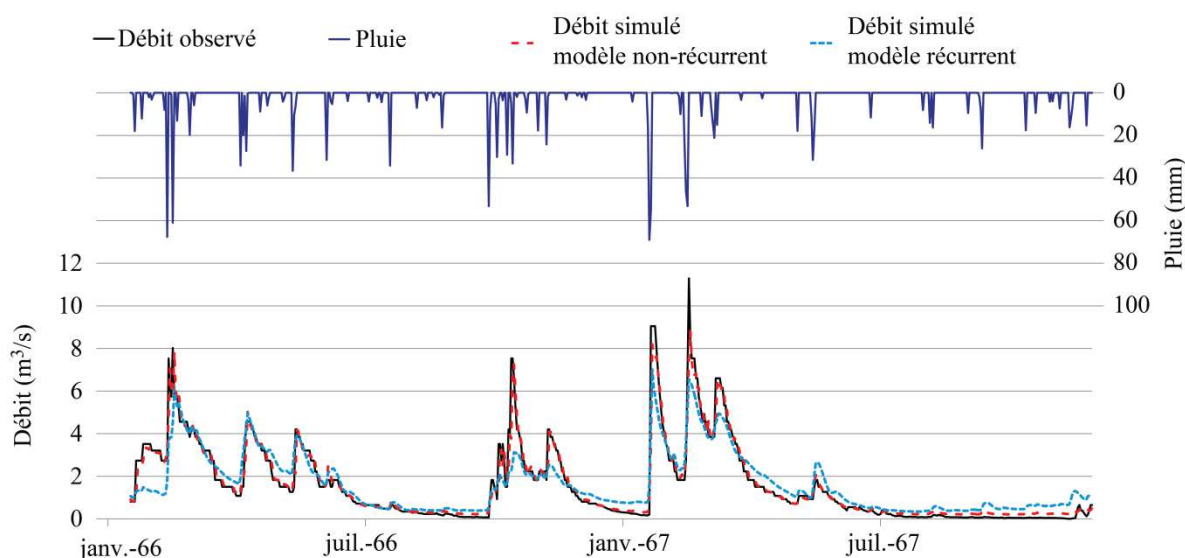


Figure 41 : Hydrogrammes observés et simulés par les deux modèles sur l'ensemble de test (1966-1967).

Finalement, le modèle non-récurrent est très performant, avec seulement une sous-estimation du débit lors des crues les plus importantes. Il faut savoir que le maximum de débit enregistré lors de la crue majeure de 1967, est aussi le maximum de la base de données. Le modèle n'a donc jamais été confronté à une telle situation durant l'apprentissage. De plus, étant donnée la variabilité temporelle et spatiale de la pluie ainsi que l'alimentation par de pertes, il est possible que l'information présentée en entrée ne soit tout simplement pas suffisante pour calculer correctement l'augmentation du débit.

La sortie obtenue avec le modèle récurrent ressemble à un lissage de la sortie mesurée, on peut donc en déduire que le modèle récurrent fournit, *a priori*, une estimation de l'état général du système, sans pour autant retranscrire les oscillations plus rapides et de plus forte amplitude. Les capacités du modèle récurrent à simuler les oscillations et l'état général de l'hydrosystème ont été étudiées et présentées en session orale lors de la 8<sup>ème</sup> conférence de l'Association Internationale des Géomorphologues du 27 au 30 août 2013 à Paris. Ces travaux ont montré que la modélisation du signal de débit, filtré par des moyennes mobiles d'effectifs compris

entre 1 et 32 jours selon une échelle dyadique ( $2^n$ ), présentait des performances croissantes liées à l'augmentation du lissage. Cette observation est en accord avec le fait que les modèles par réseaux de neurones apprennent mieux les séries Gaussiennes (maximum de vraisemblance). En effet, le filtrage passe-bas des données a eu pour conséquence de faire tendre les séries de débits vers des séries Gaussiennes, comme l'ont soulignées les valeurs d'asymétrie et d'aplatissement des distributions.

Ainsi, le modèle récurrent présenté dans ce chapitre, affiche une bonne représentation globale et en phase du système naturel. La section suivante s'appuie sur l'étude des poids affectés aux entrées par le modèle pour comprendre le comportement du modèle et expliquer les erreurs qu'il commet.

#### 5.4.3.2. ETUDE DE LA PRISE EN COMPTE DES ENTREES PAR LE MODELE

L'amélioration du modèle et de sa représentativité passent par une étude approfondie des paramètres estimés par le modèle à l'issue de l'apprentissage. La valeur de ces coefficients est utilisée pour estimer la contribution (le « poids ») des différentes variables d'entrée selon la méthode « KnoX » (Knowledge eXtraction : Kong-A-Siou et al., 2013a).

La Figure 40 comporte les notations des paramètres du modèle (en rouge) utilisés pour le calcul de la contribution d'une entrée à un instant  $k$  dont l'équation est donnée ci-dessous :

$$P(u_i(k)) = w_{ji} \sum_{n=1}^{Nc} (w_{\sigma_n j} w_{S\sigma_n})$$

La contribution  $P$  (ou poids) de l'entrée  $u_i$  à l'instant  $k$  est égale au produit du coefficient  $w_{ji}$  (entre l'entrée  $i$  et le neurone intermédiaire  $j$ ) avec la somme (de  $n=1$  à  $n=Nc$ ) des produits des coefficients  $w_{\sigma_n j}$  et  $w_{S\sigma_n}$  relatifs aux neurones cachés  $\sigma_n$ .

L'utilisation des paramètres tels que définis dans la Figure 40 permet de développer le calcul de la contribution pour une entrée  $u_i$  à l'instant  $k$  :

$$P(u_i(k)) = w_{ji}(w_{\sigma_1 j} w_{S\sigma_1} + w_{\sigma_2 j} w_{S\sigma_2} + w_{\sigma_3 j} w_{S\sigma_3})$$

Étant donné que toutes les variables d'entrée ont une fenêtre temporelle de 16 jours, si l'on s'intéresse à la contribution  $P$  des variables d'entrée  $V$ , il faut effectuer la somme des poids des 16 entrées comme suit :

$$P(V(k)) = \sum_{i=1}^{16} P(u_i(k))$$

L'étude des contributions des variables va nous permettre d'étudier le fonctionnement des modèles et la prise en compte des entrées au travers de la comparaison entre les modèles récurrent et non-récurrents.

Les résultats obtenus sur la contribution des variables d'entrée des deux modèles sont consignés dans le Tableau 13.

Tableau 13 : Contributions affectées aux variables d'entrée par les modèles récurrent et non-récurrent.

|                      | $C_1$ | $C_2$ | $C_7$ | $C_{19}$ | $C_{51}$ | Pluie totale | ETP | Q   |
|----------------------|-------|-------|-------|----------|----------|--------------|-----|-----|
| <b>Récurrent</b>     | 0,3%  | 0,5%  | 3%    | 14%      | 16%      | <b>34%</b>   | 57% | 9%  |
| <b>Non-récurrent</b> | 4%    | 5%    | 7%    | 16%      | 18%      | <b>50%</b>   | 17% | 33% |

La contribution de la pluie totale correspond à la somme des contributions des 5 composantes de pluie ( $C_1$  à  $C_{51}$ ), on fera donc la distinction entre la contribution des variables correspondant aux composantes et la contribution de la pluie totale qui correspond à leur somme, soit à 80 entrées.

Dans le cas du modèle non-récurrent, on observe que la variable dont la contribution est la plus importante est celle du débit mesuré au temps précédent avec 33% de contribution au calcul de la sortie. On constate ensuite que l'évapotranspiration potentielle et les deux composantes temporelles contenant les informations à moyen ( $C_{19}$ ) et long terme ( $C_{51}$ ), ont des contributions comprises entre 15 et 20%. Les 3 composantes contenant les informations à court terme ont une contribution plus faible (entre 4 et 7%). Si on s'intéresse aux informations apportées en entrée du modèle, on constate que l'information totale de pluie, qui représente la somme des composantes de pluie, est finalement l'information qui a le plus de poids (50%) sur la sortie calculée. Il semble donc que le modèle non-récurrent utilise en partie les informations de débit mesuré au temps précédent comme information d'état. La composante de pluie  $C_{51}$ , dont nous avons souligné les importantes similitudes avec le débit observé, se voit affecter une contribution qui laisse supposer que cette variable contribue elle aussi à l'estimation de l'état général du système. Étant donné l'inertie du système et le filtrage qu'il opère, les autres composantes de pluie pourraient *a priori* n'être utilisées que pour calculer l'incrément du débit par rapport à la sortie mesurée au temps précédent.

Les contributions affectées par le modèle récurrent aux variables sont sensiblement différentes de celles affectées par le modèle non-récurrent. On observe que le débit estimé au temps précédent a une contribution faible (9%), alors que l'évapotranspiration potentielle a une contribution très importante (57%). Les informations à moyen et long terme ( $C_{19}$  et  $C_{51}$ ) ont des contributions proches de celles affectées par le modèle non-récurrent. Les informations sur le court terme ( $C_1$ ,  $C_2$ ,  $C_7$ ) ont des contributions très faibles, voir quasi nulles pour  $C_1$  et  $C_2$  (respectivement 0,3 et 0,5%).

Les observations faites lors de l'étude des performances du modèle récurrent peuvent être expliquées par les poids affectés aux différentes variables. En effet, la sortie du modèle récurrent (Figure 41), qui apparaît comme un lissage par filtrage passe-bas du débit observé, peut être expliquée par la faible contribution des composantes de pluies contenant l'information sur les variations à court terme. Or, la faible contribution de la variable du débit estimé à l'instant précédent suggère que le modèle fait appel à d'autres variables pour estimer cet état. La contribution totale de la pluie étant essentiellement due aux contributions des composantes  $C_{19}$  et  $C_{51}$ , on peut supposer qu'une partie des informations à moyen et long terme sont utilisées pour estimer l'état général qui est relativement bien représenté. En revanche les oscillations rapides (hautes fréquences) ne sont pas reproduites par le modèle car celui-ci n'affecte pas suffisamment d'importance aux composantes de pluies à court terme.

L'observation des contributions permet également de constater que l'information d'évapotranspiration potentielle est celle qui a le plus de poids, son poids est même supérieur à celui de la pluie totale. Or, même si d'après certains auteurs, l'évapotranspiration n'est pas l'entrée qui contribue le plus au débit à la source du Lez, tels que les modèles réservoirs KARINE (Thiery et Bérard, 1984) ou VENSIM (Fleury et al., 2009), les valeurs d'évapotranspiration réelle estimées en Languedoc-Roussillon sont importantes, rarement inférieures à 500 mm soit 40% à 60% de la pluviométrie.

Ceci nous incite à chercher à comprendre et à expliquer l'importance de la variable d'ETP pour le modèle récurrent. Pour ce faire, nous allons étudier conjointement l'erreur commise par le modèle et la variable d'ETP.

Le calcul de l'erreur du modèle récurrent permet de séparer les valeurs positives, qui correspondent à la sous-estimation du débit naturel, et les valeurs négatives qui correspondent à la surestimation du débit naturel par le modèle récurrent (Figure 42).




Figure 42 : Hydrogramme du débit mesuré et erreurs du modèle récurrent (en  $\text{m}^3/\text{s}$ ) et série d'ETP (ici sans dimension).

Sur cette figure, on constate que la surestimation est plus fréquente, mais de moindre amplitude que la sous-estimation. La courbe d'évapotranspiration potentielle permet de s'apercevoir que les débits sont sous-estimés lorsque les valeurs d'ETP sont faibles, en revanche, l'augmentation des valeurs d'ETP entraîne *quasi* systématiquement une surestimation du débit. Or, la série d'ETP a une cyclicité annuelle avec un maximum en été et un minimum en hiver. Il apparaît donc que les débits sont surestimés en période sèche et sous-estimés en période humide. Cette observation peut s'expliquer par le fait que le modèle utilise l'évapotranspiration potentielle en tant qu'information sur l'état du système comme le confirme l'importance de la contribution affectée à cette variable par le modèle récurrent.

#### 5.4.4. CONCLUSIONS SUR LA DECOMPOSITION MULTIECHELLE DES PLUIES POUR ALIMENTER LE MODELE RECURRENT

L'application de la *Taverlette* pour décomposer le signal de pluie et en isoler des composantes temporelles a permis d'étudier le fonctionnement des modèles récurrent et non-récurrent. Dans un premier temps, il ressort que la décomposition choisie est facilement applicable et que la flexibilité dans le choix des composantes permet de cibler et de séparer les informations relatives à différents processus supposés ou connus.

Dans un second temps, il est possible de comparer les performances du modèle récurrent avec les composantes de pluie en entrée et celles du modèle récurrent sélectionné par la validation croisée (appelé ANN dans la section 5.3) qui reçoit l'information complète de pluie en entrée. Les deux modèles n'ont pas été configurés avec le même découpage des ensembles d'apprentissage, de test et d'arrêt, mais étant donné les scores de validation croisée obtenus (qui illustrent la capacité de généralisation du modèle) il est possible de comparer ces deux modèles. On constate donc que l'apport des composantes de pluies, en entrée du modèle, permet d'améliorer les performances de ce dernier puisque le modèle ANN a un score de Nash de 0,68 alors que celui du modèle récurrent alimenté par des composantes est de 0,80.

La comparaison des modèles récurrent et non-récurrent permet d'aborder l'importance de l'information d'état du système. Tout en gardant en mémoire les réserves que nous avons présentées au Chapitre 2 sur le fait de considérer la variable de débit comme une information d'état, nous pensons pouvoir considérer cette variable, dans cette discussion comme une information d'état. On a pu constater une bien meilleure performance du modèle alimenté par l'information d'état mesurée tandis que l'autre modèle, le récurrent, a besoin d'estimer l'information d'état. Cette estimation de l'état du système semble être une étape qui sollicite les informations relatives aux basses fréquences au détriment des hautes fréquences dont les oscillations et l'amplitude ne sont pas reproduites. On note aussi que l'estimation de l'état du système sollicite la variable d'évapotranspiration non pas comme une perte pour le système, mais comme une information saisonnière de son état. Cela



entraîne donc probablement les erreurs qui ont été décrites précédemment selon qu'on se trouve en période sèche ou humide.

## 5.5. CONTRAINDRE LE MODELE POUR AMELIORER SES PERFORMANCES ET SA REPRESENTATIVITE

### 5.5.1. INTRODUCTION

Les résultats obtenus précédemment sur la contribution des entrées du modèle récurrent suggèrent que la variable d'évapotranspiration est utilisée comme une information saisonnière d'état. Cela peut s'expliquer par un manque d'information sur la pluie et l'humidité du bassin qui devraient être les entrées principales.

Les données, disponibles sur la période étudiée, ne permettent pas de tester l'hypothèse du manque d'information sur la spatialisation des pluies. D'après les observations faites sur la caractérisation statistique de la période étudiée, il ressort que le manque d'information spatiale se traduit essentiellement de façon ponctuelle. De plus, la représentativité du pluviomètre utilisé laisse supposer que l'état du système dépend plus d'informations à long terme que d'éventuelles lacunes ponctuelles.

Cependant, l'hypothèse d'un manque d'informations temporelles semble cohérente avec le fonctionnement hydrodynamique complexe du karst qui va stocker et transmettre les eaux avec des amplitudes et des déphasages dépendant des processus et des compartiments mis en jeu.

Afin de répondre aux objectifs d'obtenir un modèle représentatif de la réalité et qui permette d'extraire des informations sur le fonctionnement de l'hydrosystème, la suite de ce travail s'oriente vers une configuration du modèle alternative à celle proposée dans la section 5.3 (pour le modèle appelé ANN). Cette nouvelle configuration, qui sera appelée IANN (Information Added to Neural Network) dans la suite de ce travail, vise à alimenter le modèle par un historique de pluie plus important qui devrait permettre au modèle de mieux estimer sa sortie, et surtout de prendre correctement en compte ses entrées. Une partie de cette étude a été présentée lors de la conférence internationale E3D (Eau, Déchets et Développement Durable) en juin 2014 à Alès et a fait l'objet d'un chapitre de livre à paraître dans les Presses des Mines, qui est inséré dans la section suivante comme base pour un développement plus approfondi.

Cet article propose donc d'utiliser les informations sur les processus supposés extraits de la réponse impulsionnelle pour alimenter le modèle IANN avec des fenêtres de pluies adaptées au fonctionnement hydrodynamique du Lez. Le modèle IANN est ensuite étudié et comparé au modèle ANN au travers de l'étude du poids des variables d'entrées et donc des processus empiriques.

### 5.5.2. ARTICLE SUR LA MODELISATION HYDRODYNAMIQUE PAR APPRENTISSAGE STATISTIQUE CONTRAINDRE PAR LES INFORMATIONS EXTRAITES DU CORRELOGRAMME CROISE

# MODELISATION HYDRODYNAMIQUE D'UN HYDROSYSTEME KARSTIQUE PAR RESEAUX DE NEURONES : CONTRAINDRE LE MODELE POUR AMELIORER SES PERFORMANCES. ETUDE DE CAS SUR L'HYDROSYSTEME DU LEZ

Taver Virgile<sup>(1,2)</sup> – Anne Johannet<sup>(1)</sup> – Séverin Pistre<sup>(2)</sup> – Valérie Borrell Estupina<sup>(2)</sup> – Marc Vinches<sup>(1)</sup>

1. Ecole des mines d'Alès, Laboratoire de Génie de l'Environnement Industriel

6 avenue de Clavières, 30319 ALES

2. Université Montpellier 2, laboratoire HydroSciences Montpellier

300, avenue du Professeur Emile Jeanbrau, 34095 Montpellier

Adresse mail de correspondance : [anne.johannet@mines-ales.fr](mailto:anne.johannet@mines-ales.fr)

La connaissance du fonctionnement des systèmes karstiques représente un enjeu considérable à l'échelle planétaire tant pour la ressource en eau (près de 25% de la population mondiale consomme de l'eau issue du karst) que pour leur influence sur la genèse de certaines crues. La difficulté d'étude des systèmes karstiques provient de leur grande hétérogénéité, tant géologique que due à la fracturation, de l'occupation du sol ou des prélèvements anthropiques d'eau. Du fait de cette hétérogénéité la géométrie et les propriétés physiques ne peuvent pas toujours être identifiées. Dans ce contexte, le paradigme systémique permet d'apporter une réponse en atteignant une connaissance sur ces systèmes au travers de la relation entre leurs signaux d'entrée et de sortie. Ainsi, le travail présenté dans ce travail s'inspire de l'approche systémique définie par [1984, Mangin]. L'analyse de la réponse impulsionnelle du système permet d'identifier certains processus sous-jacents que l'on peut représenter et quantifier. Ce travail, s'il part d'une analyse entrées-sorties linéaire, bien évidemment imparfaite dans le cas des hydrosystèmes complexes, propose de poursuivre l'étude en utilisant un modèle de réseaux de neurones artificiels (ANN) qui prend en compte la non-linéarité. Dans cette étude nous proposons de : 1) contraindre le modèle grâce aux informations obtenues par les analyses linéaires afin de rendre celui-ci physiquement interprétable, 2) estimer la contribution des différents processus théoriques. Appliquée à l'hydrosystème du Lez (France), cette démarche a permis de mettre en évidence certains des processus internes de l'aquifère, et par ce biais, d'améliorer la modélisation réalisée par le réseau de neurones.

Mots-clés : karst, réponse impulsionnelle, réseaux de neurones

## 1. INTRODUCTION

La croissance de la population, et donc de la pression anthropique, affecte les ressources en eau, ce qui constitue un enjeu majeur au niveau de l'environnement, sanitaire, politique et économique. La compréhension des systèmes hydrologiques, et plus particulièrement des aquifères karstiques, est très étroitement liée à l'évolution des approches directes (instrumentation, études *in situ*) et indirectes (approche systémique, modélisation). Ce travail présente une méthode novatrice d'étude et de modélisation hydrodynamique d'un système karstique par l'utilisation conjointe d'analyses linéaires et d'un modèle non-linéaire appliqués aux signaux d'entrée et de sortie du système. Dans un premier temps l'hydrosystème sujet de cette étude : l'hydrosystème du Lez est présenté,

suivi des méthodes de modélisation linéaires et des réseaux de neurones. L'application de ces méthodes à l'hydrosystème du Lez est ensuite envisagée et les résultats obtenus sont discutés.

## 2. AQUIFERE KARSTIQUE DU LEZ

### SYSTEME KARSTIQUE

Le karst est un ensemble géomorphologique complexe et très hétérogène qui résulte d'une combinaison de processus appelé la karstification [1996, Bakalowicz]. La karstification se met en place au sein de roches carbonatées qui ont été affectées par des épisodes tectoniques dont résultent des déformations, de la fracturation conduisant à la mise en contact de formations géologiques aux propriétés hydrodynamiques différentes. C'est ensuite l'eau, acidifiée par la matière organique des sols, qui va s'infiltrer, sous l'effet d'un gradient hydraulique, dans les vides (fractures, failles) et dissoudre la roche. La karstification va ainsi produire des réseaux souterrains au développement et à l'extension très variable.

### 2.2. AQUIFERE KARSTIQUE DU LEZ

Situé en bordure de la Méditerranée, dans l'Hérault (France), le Lez prend sa source à environ 10 km au nord de Montpellier pour se jeter dans la mer au niveau de la ville de Palavas-les-flots. L'aquifère donnant naissance à la source du Lez constitue une ressource majeure pour l'alimentation en eau potable de l'agglomération de Montpellier (près de 400 000 habitants). De ce fait, le système karstique du Lez est étudié depuis les années 1970 [1976, Marjolet et Salado ; 1979, Paloc ; 2011, Kong-A-Siou], ce qui a permis d'améliorer la connaissance du système et de permettre son exploitation à des fins d'alimentation en eau potable. L'aquifère karstique du Lez s'étend sur près de 380 km<sup>2</sup> [1983, Bérard], la [Figure 1] présente schématiquement ce bassin hydrogéologique et sa complexité.




Figure 1 : Bloc-diagramme de l'aquifère karstique du Lez. D'après [1979, Paloc]

De plus, le climat méditerranéen se caractérise par des étés chauds et secs, et de fortes précipitations en automne et au printemps. On a donc un système dont l'état est marqué par d'importants étiages qui entraînent la déconnexion de réseaux hydrologiques annexes du réseau principal. Par opposition, les périodes de hautes reconnectent ces réseaux périphériques ce qui a pour effet d'augmenter les zones de contribution. On peut aussi observer la mise en activité d'exurgences temporaires du système durant les crues.

## 3. APPROCHE SYSTEMIQUE DU KARST

Le fonctionnement complexe du système karstique peut être schématisé comme un filtre, une boîte noire, qui transforme des signaux d'entrée (pluie, prélèvements...) en signaux de sortie (débit, niveau piézométrique). L'étude de ces signaux et de leurs relations permet d'obtenir des informations sur le fonctionnement du système.

### 3.1. REPONSE IMPULSIONNELLE

L'approche systémique telle que elle a été définie dans les travaux de [1975, Mangin ; 1984, Mangin] s'appuie sur des analyses linéaires corrélatoires et spectrales. L'étude de la réponse impulsionnelle (RI) est obtenue par le calcul de la corrélation linéaire [1984, Mangin] entre la pluie, considérée comme l'impulsion, et le débit, qui correspond à la sortie du système. L'analyse de la RI nous permet de : 1) vérifier la causalité de la relation pluie-

débit, 2) connaître le temps de réponse du système grâce au pic de corrélation, 3) identifier les processus qui la composent par étude des ruptures de pentes et des pics mineurs.

## 3.2. MODELISATION PAR RESEAUX DE NEURONES

Les réseaux de neurones sont des outils mathématiques qui s'inspirent de la capacité des cerveaux vivants à apprendre. Ces méthodes ont pour but d'apprendre une relation entrée-sortie non-linéaire et mal connue.

### 3.2.1. L'APPRENTISSAGE

L'apprentissage consiste en un ajustement itératif des paramètres du modèle afin de minimiser l'erreur quadratique de modélisation. On définit donc une fonction de coût (erreur quadratique) qui doit être minimisée par l'application d'une règle d'apprentissage (Levenberg Marquard) [2008, Dreyfus *et al.*] afin d'optimiser le modèle.

### 3.2.2. FONCTIONNEMENT D'UN NEURONE

Le neurone est un opérateur mathématique qui : *i*) effectue la somme pondérée de ses entrées (calcul du potentiel), *ii*) applique une fonction non-linéaire (fonction d'activation) à cette somme. L'importance des entrées est quantifiée par l'ajustement des paramètres du modèle.

### 3.2.3. ARCHITECTURE

L'architecture correspond à l'organisation du réseau (graphe de connexion entre les neurones). Ce travail se base sur l'utilisation d'une architecture particulière : le perceptron multicouche. Cette architecture est très utilisée pour ses propriétés d'approximation universelle [1989, Hornik *et al.*] et de parcimonie [1993, Barron], ce qui signifie que cette architecture peut modéliser toute fonction non-linéaire dérivable, tout en étant « économe » en paramètres.

### 3.2.4. VARIABLES DU MODELE

Les variables utilisées pour ce travail sont les pluies mesurées à Valflaunès [Figure 1], le débit à la source et l'évapotranspiration potentielle (ETP) (représentée par une courbe gaussienne). La base de données, au pas de temps journalier, couvre une période de 1950 à 1967. Les pluies et l'ETP sont appelées variables d'entrée exogènes, on utilise aussi comme entrée le débit simulé au temps précédent, ce qui introduit un bouclage dans le modèle ; ce dernier est donc un modèle récurrent.

### 3.2.5. SELECTION DU MODELE

L'objectif du modèle neuronal est d'être capable de généraliser à des situations qui n'ont pas été rencontrées lors de la phase d'apprentissage. Il a été montré qu'il faut faire appel à des méthodes de sélection de la moindre complexité et de régularisation afin d'éviter le surajustement [2011, Kong A Siou]. Pour cela on peut utiliser la validation croisée [1974, Stone] ou l'arrêt précoce [1995, Sjoberg *et al.*]. Dans cette étude, la validation croisée est utilisée pour sélectionner la complexité du modèle (nombre de variables, de neurones) ; elle sert donc aussi pour sélectionner la taille des fenêtres d'entrées, par exemple l'historique des précipitations prises en compte.

### 3.2.6. EVALUATION DE LA QUALITE DU MODELE

Les performances du modèle sont évaluées par le calcul du critère de Nash [1970, Nash et Sutcliffe] sur un ensemble séparé des ensembles d'apprentissage et de sélection de la complexité (validation croisée, ensemble arrêt). Ce critère est le plus utilisé en hydrologie, il rend compte de la performance globale du modèle. Le critère de Nash est également utilisé pour calculer le score de validation croisée [2011, Kong-A-Siou *et al.*].

## 3.3. MODÈLE IANN (INFORMATION ADDED TO NEURAL NETWORK)

Dans le domaine de l'hydrologie, les réseaux de neurones sont reconnus pour leur capacité à réaliser la prévision. L'approche "boîte noire" qu'ils représentent est critiquée du fait de l'absence d'interprétabilité physique du modèle. Par opposition, l'objectif de ce travail est d'utiliser les informations de la réponse impulsionnelle pour contraindre le modèle ANN, afin de mieux comprendre ce modèle.

### 3.3.1. CONSTRUCTION DU MODELE IANN

Les informations sur les processus qui composent la RI sont utilisées pour dimensionner des fenêtres d'entrées de pluie du modèle. Ce n'est donc plus une unique fenêtre de pluie obtenue par validation croisée, qui est appliquée au modèle, mais plusieurs fenêtres de pluies correspondant à des processus différents de transfert au sein du système [Figure 3]. Afin d'éviter l'explosion du nombre de paramètres, et de contraindre l'architecture du modèle par l'information issue de la réponse impulsionnelle, chaque fenêtre correspondant à un processus est reliée à un neurone supplémentaire, dont la fonction d'activation est linéaire. Chacun des neurones linéaires est ensuite relié à la couche de neurones cachés (où se situe la non-linéarité). On obtient donc un modèle qui : *i*) représente les contributions des différents processus empiriques, *ii*) prend en compte un historique de pluie plus important que le modèle ANN, ce qui permet de ne pas négliger les processus à long terme qui peuvent conditionner le débit de base du système. Le modèle n'est plus considéré comme une "boîte noire".

### 3.3.2. RECUPERATION D'INFORMATION A PARTIR DU MODELE IANN

L'extraction d'informations sur le système à partir du modèle IANN est inspirée par la méthode KnoX [2011, Kong A Siou] qui a été appliquée pour connaître la contribution de 4 zones de l'aquifère karstique du Lez. Cette méthodologie consiste à étudier les contributions des entrées du modèle (en prenant en compte les paramètres qui lient cette variable au modèle). Elle permet d'évaluer la contribution relative des entrées (pluie, ETP, débit récurrent), et par là de confronter le système réel et sa modélisation. Dans le cas du modèle IANN, cette méthode permet également d'estimer les contributions respectives des différents processus empiriques qui interviennent selon différentes échelles temporelles.

## 4. APPLICATION

### ANALYSE LINEAIRE DE LA REPOSE IMPULSIONNELLE

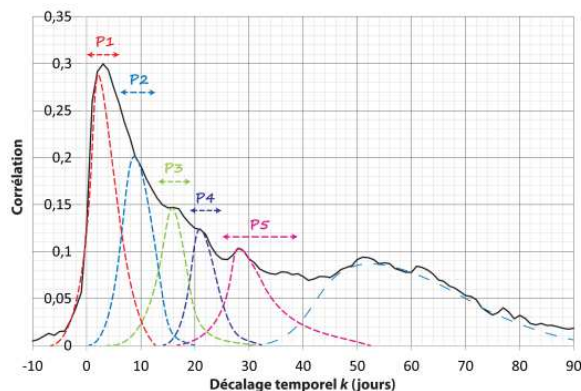


Figure 2 : Réponse impulsionnelle (en noir) et identification schématique des processus sous-jacents (en couleurs).

Sur la [Figure 2] on observe que la causalité de la relation pluie-débit est bien vérifiée (le pic se situe sur les abscisses positives). Bien qu'issue d'une analyse linéaire, la réponse impulsionnelle est complexe, nous pouvons dégager de manière graphique des processus supposés la composer. Cinq processus pour lesquels la réponse impulsionnelle dépasse la valeur 0,1 ont ainsi été identifiés de manière empirique. Le seuil de 0,2 en-deçà duquel le débit n'est plus statistiquement linéairement corrélé à la pluie [1975, Mangin] n'a pas été strictement respecté afin d'évaluer si ces processus ont une utilité dans un contexte différent de modélisation non-linéaire par réseaux de neurones.

### 4.2. COMPARAISON DES MODELES ANN ET IANN

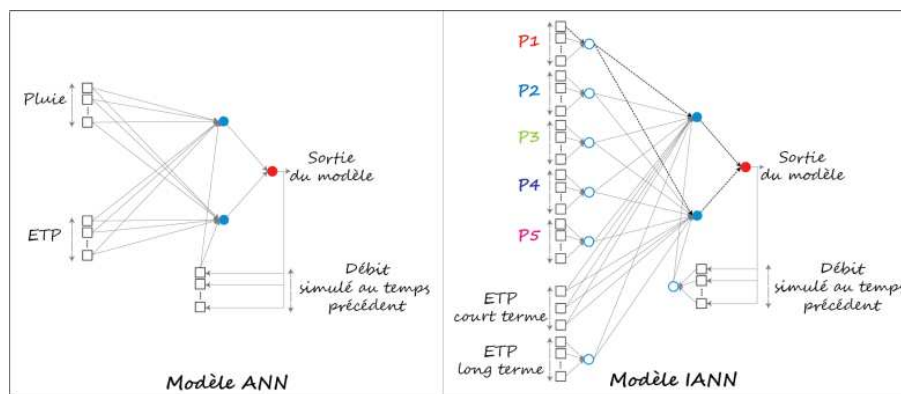


Figure 3 : Architecture des modèles ANN et IANN. Les carrés représentent les entrées. Les ronds sont des neurones : (rouge : de sortie) ; (bleu plein : cachés) ; (bleu et blanc : identité). Les fenêtres de  $P_1$  à  $P_5$  sont les fenêtres de pluie correspondant aux processus identifiés sur la réponse impulsionnelle [Figure 2]

TABLEAU 1 : Taille des fenêtres de pluie des deux modèles.

|      | Pluie totale | $P_1$ | $P_2$ | $P_3$ | $P_4$ | $P_5$ |
|------|--------------|-------|-------|-------|-------|-------|
| ANN  | 5            |       |       |       |       |       |
| IANN | 39           | 7     | 8     | 7     | 7     | 15    |

Sur la [Figure 3] on observe les architectures obtenues par les deux méthodes (validation croisée et contrainte par l'information). L'architecture du modèle IANN est plus complexe, mais comme on peut le voir dans le [Tableau 2], les performances du modèle IANN sont sensiblement meilleures. Dans le [Tableau 1] on constate que l'historique de pluie du modèle IANN est plus étendu dans le temps ce qui permet de prendre en compte des processus à plus long terme qui contribuent au débit de base. Le modèle IANN a donc moins besoin de compenser le manque d'information par l'utilisation des variables d'ETP et de débit simulé comme le fait le modèle ANN. Ceci est confirmé par le fait que dans le [Tableau 2], on constate que le modèle ANN affecte à peu près les mêmes poids aux 3 variables d'entrée (pluie, ETP, débit simulé) tandis que le modèle IANN affecte un poids plus important pour la variable de pluie, cette dernière prenant en compte les précipitation à plus longue échéance.

TABLEAU 2 : Bilan des modèles ANN et IANN. La complexité du modèle est représentée par le nombre total de paramètres du modèle ( $P$ ). Les performances des modèles sont représentées par : *i*) le score de Nash de validation croisée ( $N_v$ ), *ii*) le score de Nash obtenu sur les ensembles de test ( $N_t$ ). Les contributions relatives des entrées (pluie, ETP et débit simulé ( $Q_{sim}$ )) des modèles sont exprimées en pourcentage.

|      | $P$ | $N_v$ | $N_t$ | Pluie | ETP   | $Q_{sim}$ |
|------|-----|-------|-------|-------|-------|-----------|
| ANN  | 38  | 0,68  | 0,68  | 35,8% | 34,1% | 30,1%     |
| IANN | 94  | 0,74  | 0,77  | 74,7% | 18,7% | 6,6%      |

### 4.3. INFORMATIONS EXTRAITES DU MODELE IANN

TABLEAU 3 : Contribution des pluies représentant les différents processus représentés par le modèle IANN.

|                   | $P_1$ | $P_2$ | $P_3$ | $P_4$ | $P_5$ |
|-------------------|-------|-------|-------|-------|-------|
| Contribution en % | 42,9  | 34,4  | 11,6  | 1,6   | 9,5   |

On constate que les processus  $P_1$  (de  $t=0$  à  $t=-6$  jours) et  $P_2$  (de  $t=-6$  à  $t=-13$  j) sont ceux qui ont le plus d'importance, globalement sur l'année, ce qui correspond à un transfert relativement rapide. Cette observation est cohérente avec l'analyse linéaire de la RI [Figure 2]. On observe également que le processus  $P_5$  (de  $t=-25$  à  $t=-39$  j) a plus de poids que le processus  $P_4$  (de  $t=-19$  à  $t=-25$  j) ce qui est explicable par la durée plus importante qu'il représente.

## 5. CONCLUSION

Cette étude de modélisation hydrodynamique de l'aquifère karstique du Lez a permis de mettre en évidence que l'utilisation de l'information obtenue par l'étude de la réponse impulsionnelle du système permet de mieux dimensionner le modèle neuronal par rapport à un dimensionnement à l'aide de la validation croisée. Les simulations obtenues sont meilleures et la sélection des variables, point critique de la conception d'un modèle à réseaux de neurones, plus rapide. Le modèle ainsi conçu, noté IANN, semble de plus approprié pour extraire des caractéristiques du modèle et ainsi obtenir des informations sur le fonctionnement non-linéaire du système physique. Ces travaux, fondés sur une méthodologie générique, représentent une première étape vers une amélioration de la compréhension du fonctionnement des hydrosystèmes complexes. Dans le cas particulier de l'hydrosystème du Lez ils restent à être confortés par des analyses plus poussées intégrant les traçages et la mise en évidence des transferts physiques d'eau au sein de l'aquifère.

## BIBLIOGRAPHIE

- [Bakalowicz, 1996] Bakalowicz, Michel, 1996, "Les processus de karstification et les différents types de karst associés.", In Mémoires de la société géologique de France, 169, 363-371.
- [Barron, 1993] Barron, Andrew R., 1993, "Universal approximation bounds for superpositions of a sigmoidal function.", *IEEE Transactions on Information Theory*, 39, 3, 930-945.
- [Bérard, 1983] Bérard, Pierre, 1983, "Alimentation en eau de la ville de Montpellier. Captage de la source du Lez étude des relations entre la source et son réservoir aquifère.", *Rapport n°2: Détermination des unités hydrogéologiques*, BRGM Montpellier.
- [Dreyfus *et al*, 2008] Dreyfus, Gérard, Samuelides, Manuel, Martinez, Jean-Marc, Gordon, Mirta-B., Badran, Fouad, Thiria, Sylvie, 2008, *Apprentissage statistique*, Eyrolles, 450 p.
- [Hornik, 1989] Hornik, Kurt, Stinchcombe, Maxwell, White, Halbert, 1989, "Multilayer feed-forward neural networks are universal approximator.", *Neural Networks*, 2, 359-366.
- [Kong-A-Siou *et al*, 2011] Kong-A-Siou, Line, 2011, *Modélisation des crues de bassins karstiques par réseaux de neurones. Cas du bassin du Lez (France)*. Thèse université Montpellier II
- [Mangin, 1975] Mangin, Alain, 1975, *Contribution à l'étude hydrodynamique des aquifères karstiques*. Thèse Université de Dijon.
- [Mangin, 1984] Mangin, Alain, 1984, "Pour une meilleure connaissance des systèmes hydrologiques à partir des analyses corrélatoire et spectrale.", *Journal of Hydrology*, 67, 1-4, 25-43.
- [Marjolet et Salado, 1976] Marjolet, Gilles et Salado, José, 1976, *Contribution à l'étude de l'aquifère karstique de la source du Lez (Hérault)*. Montpellier, Thèse Université des Sciences et Techniques du Languedoc.
- [Nash et Sutcliffe, 1970] Nash, John Eamon. Sutcliffe, John V., 1970, "River flow forecasting through conceptual models part I – A discussion of principles.", *Journal of hydrology*, 10, 3, 282-290.
- [Paloc, 1979] Paloc, Henri, 1979, "Alimentation en eau de la ville de Montpellier. Localisation d'un emplacement de captage dans le réseau souterrain de la source du Lez. Détermination de ses principales caractéristiques en préalable à l'exécution des travaux.", *BRGM/79-SGN-654-LRO*, Montpellier, BRGM.
- [Sjöberg *et al*, 1995] Sjöberg, Jonas, Zhang, Qinghua, Ljung, Lennart, Benveniste, Albert, Deylon, Bernard, Glorennec, Pierre Yves, Hjalmarsson, Hakan, Juditsky, Anatoli, 1995, "Nonlinear Black-Box Modeling in System Identification : a Unified Overview.", *Automatica*, 31, 12, 1691-1724.
- [Stone, 1974] Stone, Mervyn, 1974, "Cross-Validatory Choice and Assessment of Statistical Predictions.", *Journal of the Royal Statistical Society. Series B (Methodological)*, 36, 2, 111-147.

### 5.5.3. AU-DELA DE L'ARTICLE

La démarche et les résultats présentés dans cet article ouvrent des perspectives quant à la méthodologie de construction des modèles par réseaux de neurones, mais aussi concernant les informations que l'on peut obtenir grâce à l'étude des contributions affectées aux entrées par le modèle. Il s'agit dans un premier temps de vérifier si les performances du modèle et la prise en compte de l'information de pluie sont meilleures et plus pertinentes avec le modèle IANN qu'avec les autres modèles présentés jusqu'ici. Une étude approfondie de la contribution de chaque fenêtre de pluie est ensuite proposée. L'objectif est ici de représenter graphiquement la façon dont le modèle calcule la contribution de chaque valeur de l'historique de pluie total utilisé en entrée.

#### 5.5.3.1. CONCLUSIONS SUR LES DIFFERENTS MODELES

Jusqu'ici, 4 modèles ont été présentés et étudiés (1 non-récurrent et 3 récurrents) : i) le modèle ANN qui est un modèle dont la complexité est sélectionnée par la validation croisée, ii) les modèles récurrent et iii) non-récurrent avec les composantes temporelles de pluie en entrée (appelés par la suite « *multirésolution récurrent* » et « *multirésolution non-récurrent* »), iv) le modèle IANN. Les modèles i) et iv) ont été construits en utilisant les mêmes ensembles en apprentissage (1950-1958 ; 1962-1967), en arrêt (1959) et en test (1960-1961). Les modèles récurrent et non-récurrent utilisant la décomposition *Taverlette* ont les mêmes ensembles, à savoir 1950-1964 pour l'apprentissage, l'année 1965 pour l'arrêt et 1966-1967 pour le test. Les résultats des différents modèles peuvent toutefois être comparés en l'état grâce à la compilation des principaux résultats dans le Tableau 10.


**Tableau 14 : Récapitulatif des principaux résultats obtenus avec différentes approches de modélisation. Le score de Nash est celui obtenu sur l'ensemble de test.**

| Type de modèle   | ANN        | Multirésolution récurrent  | Multirésolution non-récurrent | IANN         |
|--|------------|--|-------------------------------|--------------|
| <b>Nombre de jours de pluie ou d'entrées de pluies</b> | 5          | 5 composantes de pluie de fenêtre temporelle de 16 jours chacune |                               | 39           |
| <b>Score de Nash</b>                                   | 0,68       | 0,80   | 0,93                          | 0,77         |
| <b>Contribution totale de la pluie</b>                 | <b>36%</b> | <b>34%</b>   | <b>50%</b>                    | <b>74,7%</b> |
| <b>Contribution de l'ETP</b>                           | 34%        | 57%  | 17%                           | 18,7%        |
| <b>Contribution du débit</b>                           | 30%        | 9%   | 33%                           | 6,6%         |

La première constatation est que le modèle récurrent sélectionné par la validation croisée est celui qui obtient les moins bonnes performances avec toutefois un score de Nash acceptable. L'étude des contributions affectées aux variables d'entrées par le modèle, indique que celui-ci attribue près d'un tiers du poids total à chacun des types de variables lors du calcul de la sortie. Dans le cas de la variable de débit estimé au temps précédent, il est envisageable que le modèle lui attribue un poids important du fait de l'effet mémoire du système tel qu'il a été défini à partir de l'autocorrélation du débit en début de chapitre. Le poids de l'ETP apparaît important ; il n'est pas impossible qu'il puisse être du même ordre de grandeur que celui de la pluie sous la latitude de l'hydrosystème du Lez. L'interface graphique du logiciel *RnfPro*, utilisé dans cette thèse, permet de suivre l'évolution des variables et de la sortie estimée au cours de l'apprentissage. Il est donc possible de visualiser l'évolution de la sortie à chaque itération comme l'illustre la Figure 43. Les données utilisées par le modèle sont toutes normalisées au seuil de 0,9 afin d'éviter l'éventuelle saturation des sigmoïdes. Sur la Figure 43, dès la quatrième itération (Figure 43c) on constate que la sortie calculée correspond à la variable d'évapotranspiration inversée et d'amplitude réduite. A ce stade, la représentation de



la sortie se résume à un état saisonnier : hautes eaux et basses eaux, qui est généré à partir de la variable d'ETP. Dès l'itération suivante, on retrouve cette cyclicité associée au poids important de l'ETP qui est utilisée comme information sur l'état saisonnier. Cette information d'état saisonnier est progressivement enrichie par l'information de pluie (Figure 43d et e). Ce suivi de l'apprentissage permet de mieux comprendre le fonctionnement du modèle, et comment il apprend les contributions de ses entrées en commençant par celle qui a le plus de poids (ETP) pour affiner petit à petit les influences des précipitations.



**Figure 43 : Représentation graphique des entrées exogènes de pluie (a), d'ETP (b) ; la sortie désirée (f) ; la sortie calculée aux itérations 4 (c), 5 (d) et 7 (e) sur la première partie de l'ensemble d'apprentissage (1951-1958) du modèle ANN.**

De tous les modèles appliqués, le modèle non-récurrent, qui utilise l'information de débit observé au temps précédent, est celui qui a les meilleures performances. Celui-ci a été utilisé afin d'effectuer une comparaison avec le modèle récurrent pour mieux comprendre ce dernier. Le modèle *multirésolution récurrent* qui utilise les composantes de pluie en entrée a montré de bonnes performances pour estimer les débits en sortie. Nous avons vu que ce modèle affecte un poids très important à la variable d'évapotranspiration. Cette observation suggère que, comme pour le modèle ANN, la variable d'ETP qui est censée représenter une perte pour le système est en fait inversée et utilisée comme information « d'état » saisonnière par le modèle, ce qui paraît cohérent avec le fonctionnement hautes eaux et basses eaux de l'hydrosystème.

Finalement, le modèle qui affiche le poids affecté à la pluie le plus important est le modèle IANN. Ce modèle affiche des performances relativement bonnes, avec un score de Nash, sur l'ensemble de test, proche de 0,8. Dans la section suivante, les résultats de l'article vont être exploités de façon plus poussée.

### 5.5.3.2. ANALYSE APPROFONDIE DES CONTRIBUTIONS AFFECTES AUX PLUIES DU MODELE IANN

Les résultats présentés dans le Tableau 3 de l'article de E3D peuvent être étudiés non pas par la contribution des processus empiriques, tels que définis dans l'article, mais par entrée individuelle de pluie. Cela permet de visualiser comment chaque pas de temps de l'historique de pluie est pris en compte. Le calcul de la contribution des entrées permet donc d'obtenir une représentation de la réponse impulsionnelle pluie-débit compte tenu des contributions des informations apportées par les autres variables. La Figure 44 apporte donc une représentation graphique de la contribution, calculée par entrée des fenêtres d'entrée de pluie, par les modèles ANN et IANN. Ces courbes de poids sont comparées à la représentation graphique de la réponse impulsionnelle obtenue par la corrélation croisée. Pour le modèle IANN, les contributions des processus empiriques sont représentées individuellement par couleurs et leur somme est représentée par la courbe noire en pointillés.




Figure 44 : Comparaison des poids affectés aux entrées de pluies par les modèles ANN et IANN et le corrélogramme croisé pluie-débit.

Dans le cas du modèle ANN, on constate que le poids maximum affecté est atteint au bout de trois jours, ce qui correspond au temps de réponse du système identifié par la corrélation croisée. Étant donnée la taille réduite de la fenêtre de pluie du modèle ANN, il n'est pas possible d'analyser, au-delà de la taille de la fenêtre de pluie (5 valeurs), la relation pluie-débit à partir des poids calculés.

L'étude des contributions des cinq processus empiriques permet de voir que chacun de ces processus présente une forme de *réponse impulsionnelle* avec au moins une phase de croissance suivie d'une phase de décroissance. La contribution des processus empiriques décroît rapidement de  $P_1$  à  $P_4$  pour ensuite remonter légèrement pour  $P_5$ . Le processus  $P_1$ , qui correspond au court terme, est celui qui a le pic dont les poids sont les plus élevés. Néanmoins, le pic est relativement aplati ce qui diffère des pics du modèle ANN et du corrélogramme croisé. Le processus  $P_2$  affiche une montée rapide, puis une phase de décroissance avec une légère rupture à 9 jours. Le processus  $P_3$  affiche un double pic et se termine par une rupture marquée avec  $P_4$  dont l'amplitude est faible mais le pic visible. Le processus empirique  $P_5$  est le plus réparti dans le temps et

semble contenir plusieurs pics, il serait donc susceptible d'être décomposé lui-même en plusieurs processus empiriques. Il faut savoir que chaque processus a un jour en commun avec chacun des processus qui l'entourent. Or, on constate que, pour ce jour en commun, le modèle n'affecte pas la moitié du poids total à chaque processus empirique, il semble donc faire des distinctions en fonction du processus d'appartenance, et attribuer les poids en fonction. On constate en effet que les valeurs des poids affectés au jour de début et à celui de fin pour  $P_3$  et  $P_4$  semblent plus cohérentes avec le reste du processus supposé que ne l'auraient été des valeurs moyennes par exemple.

La somme de ces processus (pointillés noirs Figure 44) reflète le poids total affecté aux pluies en entrée sur une profondeur de 40 jours. On constate que les poids obtenus pour les pas de temps communs à deux processus empiriques semblent cohérents avec le reste de la courbe. De plus, la courbe de corrélation croisée affiche certaines similitudes avec les poids affectés au total des entrées de pluies. On observe en effet que les ruptures de pentes et les pics des deux courbes (corrélogramme croisé et IANN) sont généralement en phase. Il faut toutefois noter que les pentes des deux courbes ne sont pas les mêmes, la courbe du corrélogramme croisé semble illustrer des processus plus inertiels, pour lesquels, à l'échelle observée, il n'y a pas de rupture aussi marquée que pour la courbe des poids affectés par le modèle IANN qui prend en compte d'autres variables que la pluie.

#### 5.5.4. CONCLUSIONS

Finalement, la comparaison des poids affectés par le modèle IANN avec le corrélogramme croisé permet de montrer que : i) le modèle IANN effectue une prise en compte cohérente de la pluie qui est l'information qui a le plus de poids sur la sortie calculée, ii) le modèle IANN peut produire une représentation de la *réponse impulsionnelle* de l'hydrosystème en tenant compte de la contribution de d'autres entrées, mais aussi d'une partie de la non-linéarité représentée par le modèle neuronal. L'utilisation de l'architecture particulière du modèle IANN, avec des neurones linéaires intermédiaires pour chaque processus pourrait être susceptible de limiter la capacité du modèle à prendre en compte la non linéarité. Celle-ci apparaît cependant au niveau de la couche de neurones cachés sigmoïdes.

Les résultats obtenus en étudiant la somme des contributions des processus empiriques suggèrent que le modèle pourrait se dispenser de cette distinction en différents processus en entrée. Le paramètre le plus important étant *a priori* la taille totale de la fenêtre de pluie, le modèle est capable de gérer l'éventuelle somme de processus sous-jacents.

L'augmentation de la taille de la fenêtre de pluie en entrée a donc amélioré sa prise en compte par le modèle. Il semble alors intéressant d'étudier si, en augmentant encore la taille de la fenêtre de pluie, on améliore la sortie du modèle ainsi que la prise en compte de la pluie. Cette hypothèse est abordée dans la section suivante qui présente les résultats obtenus pour les modèles ANN et IANN en élargissant l'historique de pluie.

### 5.6. ANALYSE DE LA REPONSE IMPULSIONNELLE PAR APPRENTISSAGE STATISTIQUE

#### 5.6.1. INTRODUCTION

Nous avons vu précédemment que l'analyse du système par les méthodes linéaires peut être utilisée pour obtenir des informations sur le fonctionnement de l'hydrosystème et pour orienter la conception du modèle récurrent. Or, les réseaux de neurones sont des outils statistiques capables d'apprendre une relation entrée(s)-sortie non-linéaire. Nous allons donc poursuivre l'étude du fonctionnement de l'hydrosystème à partir de l'exploitation des paramètres des modèles par réseaux de neurones.

Deux types d'architectures inspirées du perceptron multicouche sont proposées dans ce travail. La première correspond au modèle récurrent de type ANN et la seconde au modèle IANN.

L'utilisation de ces deux architectures devrait permettre d'appréhender la capacité des modèles par réseaux de neurones à prendre en compte un historique de pluie suffisant pour estimer les contribution rapides et retardées de la pluie.

## 5.6.2. ETUDE DE LA REPONSE IMPULSIONNELLE DE LA RELATION PLUIE DEBIT PRODUITE PAR LES MODELES RECURRENTS ANN ET IANN

### 5.6.2.1. INTRODUCTION

L'étude proposée ici vise à poursuivre la compréhension et l'amélioration du fonctionnement du modèle pour rapprocher celui-ci des observations de l'hydrosystème karstique du Lez. L'objectif est double, il s'agit d'une part d'étudier l'impact de l'élargissement de la fenêtre temporelle de pluie, et d'autre part, de comparer les comportements des modèles ANN et IANN face à cette information de pluie de taille croissante.

### 5.6.2.2. APPLICATION

La pluie étant considérée comme l'entrée principale de l'hydrosystème, on fixe la taille des autres variables et le nombre de neurones cachés à partir de l'architecture du modèle ANN déjà présentée dans la section 5.3 et rappelée dans le Tableau 15. Les architectures des deux modèles utilisés sont inspirées de celles des modèles ANN et IANN dont ils vont prendre le nom. C'est-à-dire que les deux modèles ont une structure quasi identique avec les mêmes fenêtres en entrée, mais le modèle appelé IANN possède comme son homonyme un neurone intermédiaire entre l'entrée de pluie et la couche de neurones cachés afin de réduire le nombre de paramètres.

Tableau 15 : Architecture des modèles ANN et IANN.

| Fenêtre de pluie (jours)                     | Fenêtre d'ETP (jours) | Fenêtre de $Q_{sim}$ (jours) | Nombre de neurones cachés |
|--|-----------------------|------------------------------|---------------------------|
| <b>1 à 151 jours avec un pas de 25 jours</b> | 5                     | 8                            | 2                         |

La taille de la fenêtre de pluie varie entre 1 et 151 jours, avec un pas de 25 jours pour couvrir un historique de pluie suffisamment grand sans faire augmenter démesurément le temps de calcul. La validation croisée est appliquée aux modèles pour chaque fenêtre de pluie avec 20 initialisations différentes des paramètres afin d'appréhender la sensibilité des résultats obtenus. La Figure 45 illustre la moyenne, la médiane et le maximum, pour 20 initialisations, des scores de Nash obtenus sur l'apprentissage au cours de la validation croisée ( $N_{vc}$ ). On observe que, pour les deux modèles, les maximums croissent avec la taille de la fenêtre de pluie ce qui signifie que le modèle apprend mieux avec une fenêtre de pluie plus importante. Or, on voit aussi que les valeurs centrales (moyenne et médiane) commencent à décroître au-delà de 26 jours. Cela signifie que pour une partie des résultats la qualité diminue rapidement tandis que pour le reste elle augmente plus lentement, comme le confirment les écarts croissants entre la moyenne et la médiane. Ces observations suggèrent que le modèle peut être amélioré en augmentant l'historique d'information de pluie en entrée. Cette amélioration semble toutefois se traduire par une plus forte sensibilité à l'initialisation des paramètres. Bornancin Plantier (2013) a également montré qu'en apprentissage statistique pour la modélisation hydrologique, l'initialisation des paramètres peut être déterminante.

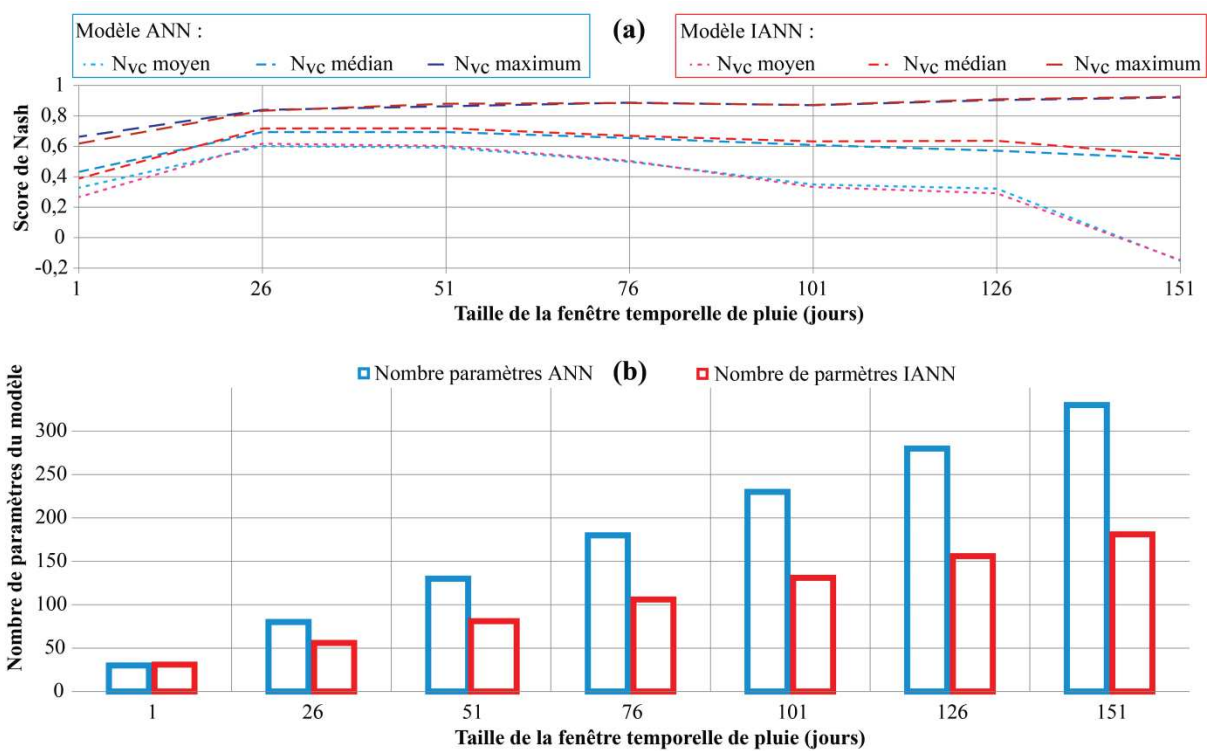


Figure 45 : Étude des performances en validation croisée (a) et du nombre de paramètres (b) des modèles ANN et IANN.

La comparaison des deux modèles permet de voir que les résultats obtenus avec la validation croisée sont très proches et que leur sensibilité à l'initialisation évolue de la même façon. Le neurone linéaire intermédiaire présent dans le modèle *IANN* ne semble pas avoir de conséquences importantes sur l'apprentissage du modèle. Cette observation est importante compte tenu de la réduction du nombre de paramètres, entre les deux modèles, que l'on peut observer sur la Figure 45b.

Si maintenant, on s'intéresse à la comparaison des contributions des entrées de pluie des deux modèles avec le corrélogramme croisé (Figure 46), on constate que les poids affectés par les deux modèles sont très proches, excepté pour le pic le plus important. On voit en effet que le pic du modèle *IANN* est plus élevé et plus dispersé que le pic du modèle *ANN*, à l'image du corrélogramme qui est lui aussi plus étendu et retardé. On constate ensuite une diminution rapide des poids affectés par les modèles jusqu'à 10 jours. Le corrélogramme affiche une décroissance plus lente, en revanche on observe, grâce aux pointillés verts (Figure 46) une rupture de pente, à 10 jours, commune aux trois courbes. On constate aussi, grâce aux pointillés verts que l'essentiel des fluctuations affichées par le corrélogramme croisé se retrouvent dans les poids affectés par les modèles. Étant donné que ces oscillations se retrouvent aussi bien dans le corrélogramme que dans les poids affectés aux pluies, il apparaît que celles-ci ont bien une réalité et ne sont pas uniquement associées au calcul du corrélogramme.




Figure 46 : Comparaison des poids affectés par les modèles ANN et IANN avec le corrélogramme croisé.

Ces observations permettent aussi de vérifier l'hypothèse émise au chapitre 4 à propos du sens de l'information contenue dans les valeurs inférieures à 0,2 du corrélogramme croisé. Il existe toutefois une différence d'amplitude dans la phase de décroissance principale ainsi que dans les oscillations retardées dans le temps. Cette différence peut s'expliquer : i) par la linéarité du calcul du corrélogramme, ii) par les poids affectés aux autres variables d'entrée des modèles qui jouent un rôle dans l'estimation de la sortie.

#### 5.6.2.3. CONCLUSIONS

Cette étude a permis de montrer que l'ajout au modèle ANN d'une couche de neurones linéaires intermédiaires, entre les entrées de pluie et la couche de neurones cachés, n'a que très peu d'effet sur la sortie. Ceci présente un intérêt considérable pour la diminution du nombre de paramètres tout en conservant un historique de précipitations très étendu.

Il apparaît finalement qu'il existe bien des contributions retardées de la pluie qui contribuent au débit de base et dont on peut avoir un aperçu avec le corrélogramme croisé. Nous avons effectivement vu que certaines informations à moyen et long terme contenues dans le corrélogramme croisé (en dessous du seuil 0,2) se retrouvent dans les poids affectés aux entrées du modèle et permettent d'améliorer les performances de ce dernier.

Ces informations, associées aux connaissances disponibles sur le système, permettent d'appréhender la répartition, dans le temps, de la réponse du système à une entrée de pluie. Ce type d'information est susceptible d'être utilisé pour gérer la ressource, anticiper l'entraînement d'une pollution par exemple, ou encore pour mieux appréhender les débits à l'étiage. L'exploitation de ces informations de poids pour étudier la relation pluie débit est limitée par la présence d'autres variables en entrée du modèle qui contribuent, elles aussi, au calcul de la sortie.

### 5.7. VERS UNE CORRECTION DES DONNEES PAR LA « MODELISATION INVERSE » D'UN MODELE NON-LINEAIRE

#### 5.7.1. INTRODUCTION

L'approche novatrice de l'assimilation de données proposée dans le chapitre 3 a montré sa capacité à améliorer de façon significative les performances du modèle récurrent sur l'ensemble de test. L'étude

proposée ici exploite cette méthode de manière duale en cherchant à corriger l'entrée afin de, en quelques sortes, effectuer une « modélisation inverse ».

Comme il a déjà été présenté au chapitre 3, l'assimilation des données pour modifier les entrées permet d'obtenir de meilleurs résultats sur la sortie calculée. Or, si l'on s'intéresse à la correction apportée aux entrées, il est possible d'obtenir des informations sur cette donnée. Dans le cas de l'assimilation des données de débit pour la correction des pluies, la correction apportée est susceptible de permettre d'estimer la pluie efficace par exemple. De plus, pour des séries comportant des lacunes, cette méthode est susceptible de corriger ces manques.

L'estimation d'une pluie efficace pourrait permettre de dispenser le modèle d'une information d'ETP, voire d'estimer l'évapotranspiration réelle. Il semble donc intéressant d'appliquer l'assimilation de données de débit pour corriger les pluies qui alimentent le modèle non-linéaire.

### 5.7.2. APPLICATION

L'application effectuée ici porte donc sur l'assimilation des données de pluies qui alimentent le modèle statique non-linéaire. Le modèle statique est choisi car ne possède en entrée aucune information sur le débit (ni observé, ni simulé) ; ainsi l'information de pluie ne parvient au modèle que grâce aux entrées de pluies. La méthode d'assimilation de données présentée au chapitre 3 nécessite l'utilisation du modèle en test. Pour ce faire, deux années (1951 et 1952) ont été utilisées en test. Ces années ont été choisies car les résultats de tous les modèles précédemment utilisés laissent supposer une lacune de données de pluies (Figure 47). Cette lacune, probablement liée à la variabilité spatiale de la pluie, entraîne systématiquement une sous-estimation notable des débits.

Tableau 16 : Performances obtenues sur l'ensemble de test (1951-1952) pour le modèle statique avec et sans assimilation de données.

|               | Modèle statique | Modèle statique après assimilation de données |
|---------------|-----------------|---|
| Score de Nash | 0,32            | 0,91  |

Le modèle statique non-linéaire, avec deux neurones dans sa couche cachée, est appliqué dans un premier temps avec une fenêtre de pluies de 150 jours. Il est en effet nécessaire de disposer d'une fenêtre de pluies importante pour compenser le fait que le modèle ne dispose pas d'information de débit en entrée. Dans le Tableau 16, on constate que les résultats obtenus sont effectivement médiocres sur cet ensemble avec un score de Nash de 0,32. La courbe bleue de la Figure 47a illustre la sous-estimation des débits par le modèle statique durant l'automne 1951 pour laquelle nous avons suspecté une lacune d'information en entrée (Figure 47).

L'assimilation de données est donc appliquée, après une étude succincte de sensibilité de la fenêtre à assimiler, pour corriger les 20 premières dates de pluie de l'historique utilisé en entrée du modèle. On s'aperçoit (Tableau 16) que les résultats du modèle sont considérablement améliorés puisque le score de Nash passe de 0,32 à 0,91 en test. Cette amélioration des performances se retrouve sur les hydrogrammes illustrés dans la Figure 47a. On voit en effet qu'après la correction des pluies par l'assimilation des données, le débit calculé est très proche du débit mesuré. La période automnale, pour laquelle nous avons supposé que l'erreur de débit était liée à une lacune d'information d'entrée, est maintenant bien représentée. Il apparaît donc que l'assimilation des données a permis de combler ou de compenser cette lacune de pluie supposée. Pour vérifier ces hypothèses, il faut s'intéresser à la modification apportée, par l'assimilation de données, aux pluies en entrée du modèle statique non-linéaire. Les précipitations, mesurées et modifiées, illustrées dans la Figure 47b font apparaître un certain nombre de différences.




Figure 47 : (a) Illustration des débits mesurés et calculés avec et sans assimilation. (b) Illustration des pluies mesurées et modifiées par assimilation de données.

Si, dans un premier temps, on s'intéresse à la période pour laquelle nous avons supposé une lacune, on cherche une différence notable dans les pluies avant et pendant la période de sous-estimation du débit par le modèle. On s'aperçoit donc que pendant l'automne, les pluies corrigées par l'assimilation de données (Figure 47b) présentent une succession d'événements qu'on ne retrouve pas dans la série des pluies mesurées. Or, la méthodologie d'optimisation de l'assimilation de données utilisée n'est pas encore suffisamment aboutie pour pouvoir affirmer que les corrections apportées correspondent exactement à la réalité. Néanmoins, les résultats obtenus, sur la représentation du débit en sortie (Figure 47a), suggèrent que les modifications apportées, sur cette période, par l'assimilation de données semblent fournir suffisamment d'informations pour estimer correctement la sortie. Il est possible que la répartition temporelle des précipitations et leurs intensités puissent se compenser pour aboutir à des sorties équivalentes. En d'autres mots, cette succession d'événement pourrait éventuellement correspondre en réalité à un nombre plus réduit d'événements mais de plus fortes intensités. L'entrée modifiée par assimilation présente un autre événement pluvieux important à la fin du mois de février 1952. Or, celui-ci est absent de la série mesurée ce qui suggère une lacune d'information probablement associée à la variabilité spatiale des précipitations.






Figure 48 : Modifications positives (rouge) et négatives (bleu) apportées aux pluies par l'assimilation et identification d'une variabilité saisonnière (noir).

L'analyse des corrections positives et négatives (Figure 48) apportées par l'assimilation de données montre que cette méthode ne fait pas que combler des lacunes supposées au niveau événementiel. On peut en effet noter qu'il existe des modifications plus distribuées dans le temps comme par exemple les corrections négatives observées durant l'été 1951. On voit ensuite que, de l'automne au printemps, les pluies subissent des corrections positives de faible amplitude et réparties dans le temps. On retrouve, dès le début de l'été 1951, de nouvelles corrections négatives de très faible amplitude. Ces corrections, schématisées de façon empirique dans la Figure 48, présentent donc un caractère saisonnier qui semble traduire : i) des pertes pour l'hydrosystème probablement liées à l'évapotranspiration en été, ii) un état hydrique du système qui favorise la transmission des eaux météoriques en période humide, iii) l'éventuelle contribution des cours d'eau temporaires durant la période humide.

L'estimation des valeurs de pluie faite lors de l'assimilation de données semble donc avoir pris en compte les apports et les pertes saisonnières. On peut donc considérer que l'assimilation des données du modèle statique apporte une estimation de la pluie efficace. Cette hypothèse semble cohérente avec les performances obtenues pour le modèle avec les valeurs de pluie assimilées. Notons cependant que ces premiers travaux sont pour l'instant exploratoires et méritent d'être approfondis.

### 5.7.3. CONCLUSIONS SUR L'ASSIMILATION DE DONNEES

L'implémentation originale de l'assimilation de données proposée dans le chapitre 3 a été appliquée à l'hydrosystème karstique du Lez au travers d'un modèle statique non-linéaire alimenté par une grande fenêtre de pluie (150 jours). Les résultats obtenus sur l'estimation des débits ont confirmé la capacité de cette méthode à améliorer considérablement la sortie du modèle statique, de la même manière que nous l'avons montré dans le chapitre 3 pour le modèle récurrent.

Les résultats obtenus lors de l'étude des pluies assimilées ont suggéré que cette méthode pouvait être utilisée pour estimer la pluie efficace et donc éviter d'apporter en entrée une variable comme l'ETP qui peut être mal prise en compte par le modèle ou ne pas représenter le phénomène physique. Nous avons aussi vu que l'assimilation de données est susceptible de combler des lacunes présentes dans la série chronologique.

L'utilisation de la modélisation par réseaux de neurones, associée à l'assimilation de données, ouvre des perspectives intéressantes tant dans le domaine de l'hydrologie que d'un point de vue méthodologique. De ce fait, la poursuite de ces travaux, en particulier en partant d'un signal de pluie artificiellement modifié devrait

permettre de vérifier si le modèle corrige correctement ce signal. Ce travail devrait faire l'objet d'une nouvelle communication et publication.

## 5.8. CONCLUSIONS GENERALES DU CHAPITRE

Nous avons présenté dans les chapitres 1, 2 et 4, que la caractérisation du fonctionnement hydrodynamique d'un hydrosystème karstique comme celui du Lez est une tâche particulièrement ardue, ce qui en fait un moteur pour le développement et la fédération des différentes approches de caractérisation. Dans ce contexte, ce chapitre s'est focalisé sur le développement méthodologique d'une approche d'étude et de modélisation globale fondée sur l'approche systémique.

La première partie du chapitre a donc été dédiée à l'analyse : i) des signaux d'entrée et de sortie de l'hydrosystème, ii) du fonctionnement hydrodynamique du système. L'utilisation des méthodes d'analyse corrélatoires et spectrales a conduit à mettre en évidence le rôle prépondérant des processus intervenant à différentes échelles de temps pour la compréhension du fonctionnement hydrodynamique.

À partir de ces résultats, nous avons orienté l'essentiel de ce chapitre vers une méthodologie de conception de modèles neuronaux alternative à la validation croisée et fondée sur l'utilisation des informations obtenues lors de l'analyse systémique. L'utilisation de ces informations pour contraindre les modèles de réseaux de neurones a pour objectif que ces derniers soient en mesure de prendre en compte et de représenter la relation pluie-débit à court et à long terme.

La méthode utilisée en premier lieu consiste à appliquer une décomposition multiéchelles temporelle du signal appelée dans le chapitre 3 la *Taverlette*. Cette décomposition est appliquée au signal de pluie afin d'alimenter les modèles récurrents et non-récurrents avec des informations sur les hautes et basses fréquences. L'étude des contributions affectées par le modèle aux entrées a permis d'appréhender la contribution de processus supposés à différentes échelles de temps.

Les hydrosystèmes peuvent de manière générale être soumis à des non-stationnarités, à des lacunes dans les données, ou encore à des pertes par évapotranspiration. Ainsi, l'utilisation de l'assimilation de données a été proposée pour : i) faire face aux conditions non-stationnaires, ii) corriger les données de pluie ou combler leurs éventuelles lacunes par modélisation inverse.

L'ensemble des résultats obtenus et la transposabilité des méthodes développées dans cette thèse ont ainsi ouvert de nombreuses perspectives pour l'étude et la modélisation des systèmes non-linéaires soumis à des conditions non-stationnaires



# CONCLUSION

Tout au long de ce mémoire nous nous sommes attachés à présenter les hydrosystèmes karstiques comme des systèmes naturels riches de par leurs ressources naturelles mais aussi par leur comportement mal connu, difficile à appréhender que nous avons décrit comme complexe. Ainsi, ce mémoire propose des développements méthodologiques pour l'étude et la modélisation hydrodynamique des karsts, ainsi que pour le prétraitement et la correction des signaux hydrologiques. La démarche générale proposée est d'associer les connaissances disponibles à différents outils d'analyse et de modélisation systémique afin de caractériser le fonctionnement hydrodynamique du karst.

Le premier chapitre s'est focalisé sur la présentation des karsts et des verrous scientifiques relatifs à la caractérisation de leur fonctionnement hydrodynamique. Ce chapitre a donc permis de souligner la complexité, la non-linéarité et la non-stationnarité de la relation entrée-sortie de l'hydrosystème. De plus, la description des différents processus hydrodynamiques a conduit à mettre en évidence l'importance des informations relatives aux hautes et basses fréquences pour la genèse des crues et pour le maintien du débit de base en période sèche.

Face aux difficultés d'étude des hydrosystèmes karstiques par les approches fondées sur la physique des processus ou sur des hypothèses conceptuelles, l'approche systémique a été présentée dans le chapitre 2 afin de pallier ces difficultés en utilisant les signaux d'entrée et de sortie ainsi que leur relation à partir des analyses corrélatoires et spectrales. Nous avons pu souligner les limites de ces méthodes dues à leur principe fondé sur la linéarité des systèmes étudiés. Dans le chapitre 2, nous avons aussi proposé des méthodes de filtrage et de décomposition temporelle des signaux adaptables en fonction des objectifs et des systèmes étudiés. Ces méthodes ont pour objectif de cibler et d'isoler les processus majeurs, grâce à leur signature temporelle, afin d'identifier leur contribution et ainsi, de mieux prendre en compte toutes les fréquences lors de l'analyse et de la modélisation.

Ainsi nous nous sommes proposé dans le chapitre 3 de revisiter cette approche systémique, armés d'outils plus récents permettant d'effectuer une modélisation non linéaire comme les réseaux de neurones. Pour ce faire, l'article publié dans *Karstologia* et les compléments qui y sont apportés ont permis de faire état des méthodes récemment développées pour la modélisation hydrodynamique des karsts par réseaux de neurones. Différentes architectures de modèles neuronaux ont été retenues afin d'approfondir la compréhension du fonctionnement du modèle pour mieux le contraindre et le rendre exploitable pour l'étude des systèmes. Ce chapitre 3 intègre un deuxième article qui porte sur l'utilisation de méthodes d'ajustement en temps réel pour améliorer la sortie des modèles neuronaux en conditions non-stationnaires. Les résultats obtenus dans cet article sont rappelés plus loin.

La description de l'hydrosystème du Lez, support pour les développements méthodologiques effectués dans cette thèse, fait l'objet du chapitre 4. Il fait état de la connaissance de ce système composite et de son fonctionnement hydrodynamique, mais aussi des différentes approches ayant déjà été utilisées dans le cadre de sa caractérisation et de sa modélisation. Ce chapitre fournit donc des bases pour l'exploitation des résultats présentés dans le cinquième et dernier chapitre.

Les apports méthodologiques obtenus lors de cette thèse s'inscrivent à la foi dans i) la caractérisation et la modélisation des hydrosystèmes karstiques, ii) le développement d'outils d'apprentissages statistiques aux paramètres exploitables et de méthodes de sélection des variables pour des systèmes naturels, complexes, non-linéaires et non-stationnaires, iii) la décomposition, l'analyse et la correction des séries chronologiques. Ces apports sont tout à fait intéressants et ont permis d'initier plusieurs des réflexions suivantes.

L'analyse croisée des signaux issus des modèles et des informations remontées du terrain nous ont permis de proposer des méthodes de sélection des variables plus à même de représenter le comportement à long terme du système, que celle utilisée classiquement et fondée sur la validation croisée. Cette approche nous a permis de donner plus de sens au modèle, de quantifier l'influence des variables dans le calcul effectué et par là même d'améliorer les performances du modèle neuronal récurrent, ouvrant par là son utilisation pour un grand nombre d'applications possibles (prospectives liées à des scénarii de changement climatique, etc ...).

L'utilisation des réseaux de neurones pour l'étude du comportement du système à différentes échelles temporelles a aussi été enrichie par le développement d'une méthode de décomposition des signaux permettant de cibler des fréquences caractéristiques et ainsi de quantifier leur importance et leur contribution au fonctionnement de l'hydrosystème.

Concernant le volet de l'analyse des systèmes non stationnaires, nous avons pu présenter les nouveaux développements réalisés pour transposer les calculs de l'assimilation de données dans le formalisme neuronal. Appliqués à deux bassins, l'un soumis à des non stationnarités sur les entrées et l'autre à des non stationnarités intrinsèques, les modèles neuronaux ont montré un comportement cohérent avec les non stationnarités étudiées. Ainsi, lorsque la non stationnarité concerne le bassin lui-même, c'est la modification en temps réel des paramètres du modèle qui apporte les améliorations les plus significatives, tandis que lorsque la non-stationnarité concerne les entrées de forçage (température et fonte des glaciers), c'est la modification des entrées qui apporte les meilleures améliorations.

Enfin nous avons pu commencer à défricher le champ ainsi ouvert en proposant d'utiliser l'assimilation de données pour estimer les entrées les mieux à même d'expliquer le débit assimilé. Ainsi nous avons pu effectuer un type de « modélisation inverse » qui s'est montré tout à fait intéressant et permet d'envisager, après une validation à réaliser, de nombreuses applications tant pour estimer les précipitations efficaces, que pour combler les lacunes sur des données. La poursuite de ces pistes passera par : i) une validation de la méthode sur un bassin virtuel afin de mieux appréhender l'impact du bruit sur le fonctionnement du modèle, ii) l'application à différents hydrosystèmes naturels.

L'ensemble des résultats obtenus et le caractère générique des méthodes développées dans cette thèse ont ainsi ouvert de nombreuses perspectives pour l'étude et la modélisation des systèmes non-linéaires soumis à des conditions non-stationnaires. Parmi les différentes pistes envisageables, on peut citer l'étude de la *réponse impulsionnelle* par apprentissage statistique ; l'étude simultanée des *réponses impulsionnelles* produites par réseau de neurones pour différents compartiments de l'hydrosystème ; utilisation des modèles récurrents et statiques développés dans le cadre de scénarios de changement climatiques ; la modification des variables d'entrée pour combler des lacunes temporelles ou spatiales.

Finalement, ce travail a permis de souligner : i) les capacités d'apprentissage des réseaux de neurones face à des systèmes complexes, non-linéaires et non-stationnaires ; ii) la pertinence de l'utilisation de modèles par réseaux de neurones, contraints et validés par les informations disponibles, pour l'étude hydrodynamique des karsts.

# BIBLIOGRAPHIE

- Andréassian, V., Perrin, C., & Michel, C. (2004). Impact of imperfect potential evapotranspiration knowledge on the efficiency and parameters of watershed models. *Journal of Hydrology*, 286(1-4), 19–35.
- Arthaud, F. et Seguret, M. (1981). Les structures pyrénéennes du Languedoc et du Golfe du Lion (Sud de la France). *Bulletin Société de la géologie de France* XXIII (1), 51-63.
- Artigue, G., Johannet, a., Borrell, V., & Pistre, S. (2012). Flash flood forecasting in poorly gauged basins using neural networks: case study of the Gardon de Mialet basin (southern France). *Natural Hazards and Earth System Science*, 12(11), 3307–3324.
- Audra, P., Mocochain, L., Camus, H., Gilli, É., Clauzon, G., Bigot, J.-Y. (2004). The effect of the Messinian Deep Stage on karst development around the Mediterranean Sea . Examples from Southern France. *Geodinamica Acta*, 6(2004), 27–38.
- Bailly-Comte, V., Martin, J.B., Scream, E.J., (2011). Time variant cross correlation to assess residence time of water and implication for hydraulics of a sink-rise karst system. *Water Resour. Res.* 47 (5).
- Bakalowicz, M. (1975). Géochimie des eaux karstiques et karstification. *Annales de Spéléologie*, 30(4), pp.581-589.
- Bakalowicz, M. (1996). Les processus de karstification et les différents types de karst associés. In *Mémoires de la société géologique de France*. Paris, pp. 363-371.
- Bakalowicz, M. (2005). Karst groundwater: a challenge for new resources. *Hydrogeology Journal*, 13(1), pp.148-160.
- Barbel-Perineau, A. (2013). *Caractérisation du fonctionnement de la zone non saturée des aquifères karstiques. Approche directe par études hydrodynamiques et hydrochimiques sur le Bassin de Recherche, d'Expérimentation et d'Observation de Fontaine de Vaucluse – Laboratoire Souterrain*.
- Bennett, N. D., Croke, B. F. W., Guariso, G., Guillaume, J. H. a., Hamilton, S. H., Jakeman, A. J., Marsili-Libelli, S., Newhama, L. T.H, Nortona, J. P., Perrin, C., Pierce, A. S., Robson, B., Seppelt, R., Voinov, A. A., Fath B. D., Andreassian, V. (2013). Characterising performance of environmental models. *Environmental Modelling & Software*, 40, 1–20.
- Bérard, P. (1983). Alimentation en eau de la ville de Montpellier. Captage de la source du Lez étude des relations entre la source et son réservoir aquifère. Rapport n°2: Détermination des unités hydrogéologiques. BRGM Montpellier.
- Bicalho, C. C. (2010). characterization of transfers in karst aquifers by natural and anthropogenic tracers. Example of a Mediterranean karst system, the Lez karst aquifer (Southern France).
- Bonnet, M., & Mattauer, M. (2010). Notice de la carte géologique 1/50 000 Montpellier (2nd ed.). BRGM.
- Bornancin-Plantier A., (2013). Conception de modèles de prévision des crues éclair par apprentissage artificiel. *Thèse de doctorat de l'Université Pierre et Marie Curie (Paris 6)*.

- Borrell Estupina, V., Ladouche, B., Malaterre, P. O., Ricci, S., Caballero, Y., Coustau, M., ... Thual., O. (2014). Forecasting and mitigation of flooding in a Mediterranean karstic watershed. *Hydrology in a Changing World: Environmental and Human Dimensions Proceedings of FRIEND-Water 2014, Montpellier, 7-10 October 2014 (Red Book IAHS Publ., 2014(365), 288–294.*
- Borrell Estupina V., Maréchal J.-C., Coustau M., Fleury P., Jourde H., Kong A Siou L., Ladouche B., Malaterre P.-O., Mazzilli N., Ricci S. (2012). Projet gestion multi-usages l'hydrosystème karstique du Lez - Modèles numériques de fonctionnement de l'hydrosystème, Rapport RP-60222-FR, 253 pp., 113 fig., 32 tab., 2 ann.
- Box, G. E. P. & Jenkins, G. M. (1976). Time series analysis: Forecasting and control. Revised edition, Holden-Day, San Francisco.
- Box, G. E. P. (1979). Robustness in the strategy of scientific model building. In Robustness in Statistics, R.L. Launer, G.N. Wilkinson, ed. (1979).
- Caetano Bicalho, C., Batiot-Guilhe, C., Seidel, J. L., Van Exter, S., & Jourde, H. (2012). Geochemical evidence of water source characterization and hydrodynamic responses in a karst aquifer. *Journal of Hydrology*, 450-451, 206–218.
- Camus, H. (2003). Vallée et réseaux karstiques de la bordure carbonatée sud-cévenole. Relation avec la surrection, le volcanisme et les paléoclimats. Thèse Doctorat , Université Bordeaux III, 692p.
- Clauzon, G. (1982). Le canyon messinien du Rhône : une preuve décisive du "dessicated deep-basin model (Hsü, Cita et Ryan, 1973). *Bull. Soc. géol. Fr*, 24(3), 597-610.
- Conroux, Y. (2007). Caractérisation du fonctionnement hydrodynamique de l'aquifère karstique du Lez (Hérault) à l'état naturel, Rapport de Master, BRGM Montpellier.
- Coustau, M., Bouvier, C., Borrell-Estupina, V., & Jourde, H. (2012). Flood modelling with a distributed event-based parsimonious rainfall-runoff model: case of the karstic Lez river catchment. *Natural Hazards and Earth System Science*, 12(4), 1119–1133.
- Delbart, C., Valdes, D., Barbecot, F., Tognelli, A., Richon, P., & Couchoux, L. (2014). Temporal variability of karst aquifer response time established by the sliding-windows cross-correlation method. *Journal of Hydrology*, 511, 580–588.
- Diersch, H.J.G. (1998). Interactive, graphics-based finite-element simulation system FEFLOW for modeling groundwater flow, contaminant mass and heat transport processes, User's Manual Release 4.7. WASY Ltd, Berlin.
- Dörfliger, N., Jourde, H., Ladouche, B., Fleury, P., Lachassagne, P., Conroux, Y., Pistre, S. & Vestier, A. (2008). Active water management resources of karstic water catchment : the example of Le Lez spring (Montpellier, South France). In World Water Congress Montpellier.
- Droque, C. (1964). Étude hydrogéologique des principales ressources de la région Nord Montpelliérain. Mémoire C.E.R.H. t. 1. U.S.T.L p. 62. 121
- Droque, C. (1971). De l'eau dans les calcaires. *Sciences Progrès Découvertes*, 3433, pp 39-44.
- Droque, C. (1974). Structure de certains aquifères karstiques d'après les résultats de travaux de forage. *Comptes Rendus de L'Académie des Sciences Paris série III*, 278, pp.2621-2624.
- Droque, C. & Grillot, J.C. (1976). Structure géologique et premières observations piezométriques a la limite du sous-système karstique de Terrieu (Perimetre experimental). *Ann. Sc. Univ. Besancon*, 25, 195-210.

- Fatmi, H. (2009). *signaux et caractérisation hydrogéologique: application aux chroniques de données obtenues aux laboratoires souterrains du Mont Terri, Tournemire et Meuse/Haute.*
- Fleury, P. (2005). Sources sous-marines et aquifères karstiques côtiers méditerranéens. Fonctionnement et caractérisation.
- Fleury, P., Ladouche, B., Conroux, Y., Jourde, H., & Dörfliker, N. (2009a). Modelling the hydrologic functions of a karst aquifer under active water management – The Lez spring. *Journal of Hydrology*, 365(3-4), 235–243.
- Fleury, P., Plagnes, V., & Bakalowicz, M. (2007). Modelling of the functioning of karst aquifers with a reservoir model: Application to Fontaine de Vaucluse (South of France). *Journal of Hydrology*, 345(1-2), 38–49.
- Ford, D.C., Williams, P.W., (1989). *Karst Geomorphology and Hydrology.* Unwin Hyman, London, 601p.
- Garry, B. (2007). *Etude des processus d'écoulements de la zone non saturée pour la modélisation des aquifères karstiques. Expérimentation hydrodynamique et hydrochimique sur les sites du Laboratoire Souterrain à Bas Bruit (LSBB) de Rustrel et de Fontaine de Vaucluse. Thèse de l'Université d'Avignon et des Pays de Vaucluse.*
- Guenoc, P., Gorini, C., Mauffret, A. (2000). Histoire géologique du Golfe du Lion et cartographie du rift oligo-aquitainien et de la surface messinienne. *Géol. Fr.* 3, p 67-97.
- Hakoun, V. (2013). *Développement d'une sonde aquatique autonome pour la cartographie des drains karstiques noyés. Simulation des écoulements par une approche couplée drains discrets - double porosité.* Université Montpellier 2.
- Harader, E., Ricci, S., Borrell Estupina, V., Boe, J., Terray, L., Colin, J., Somot, S., (soumis à *Climate Dynamics* en oct 2014). The added value of high-resolution regional climate modelling for the reproduction of daily precipitation extremes over France.
- Hausdorff, J.M., Purdon, P.L., Peng, C.K., Ladin, Z., Wei, J.Y. & Goldberger, A.R. (1996). Fractal dynamics of human gait: stability of long-range correlations in stride interval fluctuation. *Journal of Applied Physiology*, 80, 1448-1457.
- Husson, E. (2013). Interaction géodynamique/karstification et modélisation géologique 3D des massifs carbonatés : Implication sur la distribution prévisionnelle de la karstification. Exemple des paléokarsts crétacés à néogènes du Languedoc montpelliérain. Thèse de l'Université Montpellier 2.
- Jazayeri Noushabadi, M. R. (2009). *Characterisation of relationships between Fracture Network and Flow-path Network in Fractured and Karstic Reservoirs. Numérical modelling and field investigation (Lez aquifer, Southern France).*
- Jazayeri Noushabadi, M. R., Jourde, H., & Massonnat, G. (2011). Influence of the observation scale on permeability estimation at local and regional scales through well tests in a fractured and karstic aquifer (Lez aquifer, Southern France). *Journal of Hydrology*, 403(3-4), 321–336.
- Jenkins, G.M. & Watts, D.G. (1968). *Spectral Analysis and its Applications,* Holden-Day.
- Johannet, A., Kong A Siou, L., Mangin, A., Borrell-Estupina, V., Pistre, S., & Bertin, D. (2012a). Prediction of spring discharge by neural networks using orthogonal wavelet decomposition. *Neural Networks (IJCNN), 10-15 June 2012, The 2012 International Joint Conference on, p1-8.*
- Johannet, A., Mangin, A., & Vayssade, B. (2008a). Modélisation d'un système karstique par réseaux de neurones. Simulation des débits du karst du Baget-France. *Cahiers de Géographie-Collection EDYTEM.*



- Johannet, A., Taver, V., Kong-A-Siou, L., Borrell-Estupina, V., Pistre, S., Mangin, A., Bertin, D. (2012b). Les réseaux de neurones artificiels pour la modélisation hydrodynamique des aquifères karstiques: présentation générale et illustrations. *Karstologia*, 60, 45–59.
- Johannet, A., Vayssade, B., & Bertin, D. (2008b). Neural networks: from black box towards transparent box Application to evapotranspiration modeling. *International Journal of Computational Intelligence*, 4(3), 163-170.
- Jolivet, J. (2011). Comparaison de l'évolution endokarstique du réseau de Camélié avec le creusement des canyons de l'Aiguillon et du Merderis (bassin de la moyenne vallée de la Cèze, Gard, France). *Etudes de Géographie Physique*, (1), 43–54.
- Jolivet, J., & Martin, C. (2008). La morphologie karstique dans le canyon de la Cèze et sur le plateau de Méjannes-le-Clap (Garrigues nord, Gard, France) – Rapports avec l'évolution paléogéographique Mio-Pliocène. *Physio-Géo - Géographie Physique et Environnement*, II.
- Karam, Y. (1989). Essai de modélisation des écoulements dans un aquifère karstique. Exemple de la source du Lez (Hérault, France). Thèse Université Montpellier II Sciences et Techniques du Languedoc.
- Klimchouk, A. (2004). Towards defining, delimiting and classifying epikarst: Its origin, processes and variants of geomorphic evolution. *Speleogenesis and Evolution of Karst Aquifers*.
- Kong A Siou, L. (2011). Modélisation des crues de bassins karstiques par réseaux de neurones. Cas du bassin du Lez (France).
- Kong A Siou, L., Johannet, A., Borrell, V., & Pistre, S. (2011). Complexity selection of a neural network model for karst flood forecasting: The case of the Lez Basin (southern France). *Journal of Hydrology*, 403(3-4), 367–380. doi:10.1016/j.jhydrol.2011.04.015
- Kong-A-Siou, L., Cros, K., Johannet, A., Borrell-Estupina, V., & Pistre, S. (2013). KnoX method, or Knowledge eXtraction from neural network model. Case study on the Lez karst aquifer (southern France). *Journal of Hydrology*, 507, 19–32. doi:10.1016/j.jhydrol.2013.10.011
- Kong-A-Siou, L., Fleury, P., Johannet, A., Borrell Estupina, V., Pistre, S., & Dörfliger, N. (2014). Performance and complementarity of two systemic models (reservoir and neural networks) used to simulate spring discharge and piezometry for a karst aquifer. *Journal of Hydrology*, in Press.
- Labat, D., Ababou, R., & Mangin, A. (2000a). Rainfall – runoff relations for karstic springs . Part II : continuous wavelet and discrete orthogonal multiresolution analyses, 238, 149–178.
- Labat, D., Ababou, R., & Mangin, A. (2000b). Rainfall – runoff relations for karstic springs . Part II : continuous wavelet and discrete orthogonal multiresolution analyses, 238, 149–178.
- Ladouche, B., Marechal, J.-C., & Dorfliger, N. (2014). Semi-distributed lumped model of a karst system under active management. *Journal of Hydrology*, 509, 215–230. doi:10.1016/j.jhydrol.2013.11.017
- Lastennet, R., & Mudry, J. (1997). Role of karstification and rainfall in the behavior of a heterogeneous karst system. *Environmental Geology*, 32(September).
- Lofi, J. (2002). La crise de salinité messinienne : conséquences directes et différées sur l'évolution sédimentaire de la marge du Golfe du Lion. Thèse de Doctorat, Université des Sciences et Technologies de Lille.
- Maier, H.R. & Dandy, G.C. (2000). Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling and Software*, 15(1), pp.101-124.

- Maillet, E. (1905). *Essais d'hydraulique souterraine et fluviale*. Hermann, Paris. 218 pp.
- Mangin A. (1969). Nouvelle interprétation du mécanisme des sources intermittentes. C. R. Acad.Sci.Paris, 269, serie D, 2184-2186.
- Mangin, A., (1974). Contribution à l'étude hydrodynamique des aquifères karstiques. 1ère partie. *Annales de Spéléologie*, 29(3): 283-332.
- Mangin, A. (1975). *Contribution à l'étude hydrodynamique des aquifères karstiques*. Thèse de l'Université de Dijon.
- Mangin, A. (1978). Le karst, entité physique, abordé par l'étude du système karstique. (Karst as a physical unit, from the study of the karst system), AGSO, Le karst, colloque de Tarbes, pp. 21-37.
- Mangin, A. (1981). Utilisation des analyses corrélatoire et spectrale dans l'approche des systèmes hydrologiques. *CR Acad. Sci. Paris*, 293, pp.401-404.
- Mangin, A., (1982). L'approche systémique du karst, conséquences conceptuelles et méthodologiques. Reunion Monografia sobre el Karst, Larra 141–157.
- Mangin, A. (1984). Pour une meilleure connaissance des systèmes hydrologiques à partir des analyses corrélatoire et spectrale. *Journal of Hydrology*, 67(1-4), pp.25-43.
- Mangin A., (1994). Karst hydrogeology. In Gilbert J., Danielopol D.L. and Stanford J.A. Ed., Academic Press, San Diego. *Groundwater Ecology*, 43-67.
- Mangin, A. (1998). L'approche hydrogéologique des karsts. *Spéléochronos (Mons)*, (9), pp.3-26.
- Marjolet, G., & Salado, J. (1976). Contribution à l'étude de l'aquifère karstique de la source du Lez (Hérault). Thèse Université des Sciences et Techniques du Languedoc (Montpellier).
- Marsaud, B. (1997). *Structure et fonctionnement de la zone noyée des karst à partir des résultats expérimentaux*. BRGM.
- Mazzilli, N. (2011). *Sensibilité et incertitude de modélisation sur les bassins versants à forte composante karstique*.
- Oudin, L., Hervieu, F., Michel, Cl., Perrin Ch., Andreassian V., Anctil F., Loumagne C. (2005). Which potential evapotranspiration input for a lumped rainfall-runoff model? Part 2— Towards a simple and efficient potential evapotranspiration model for rainfall-runoff modelling. *Journal of Hydrology* 303 (2005) 290–306.
- Padilla, A., Pulido-Bosch, A., & Mangin, A. (1994). Relative importance of baseflow and quickflow from hydrographs of karst spring. *Ground Water*.
- Palmer, A.N., (2003). Dynamics of cave development by allogenic water. *Speleogenesis and Evolution of Karst Aquifers*, 1(1): 11.
- Paloc, H. (1979). Alimentation en eau de la ville de Montpellier. Localisation d'un emplacement de captage dans le réseau souterrain de la source du Lez. Détermination de ses principales caractéristiques en préalable à l'exécution des travaux. BRGM/79-SGN-654-LRO, BRGM, Montpellier.
- Pushpalatha, R., Perrin, C., Moine, N. Le, & Andréassian, V. (2012). A review of efficiency criteria suitable for evaluating low-flow simulations. *Journal of Hydrology*, 420-421, 171–182.

Sadier, B. (2014). 3D et géomorphologie karstique. La grotte Chauvet et les cavités des gorges de l'Ardèche. Thèse de l'Université de Grenoble.

Salomon, J.-N. (1999). Le facteur temps dans la karstification/The factor time in karstification. *Géomorphologie : Relief, Processus, Environnement*, 5(3), 195–213. doi:10.3406/morfo.1999.988

Savary, M. (2014). Inventaire, critique, analyse et traitement de la base de données pluie-hauteur en vue d'une instrumentation du Bassin versant de la Cèze (Gard). Rapport de stage de Master 2 - Hydrogéologie et Transferts.

Taver, V., Johannet, A., Borrell-Estupina, V., & Pistre, S. (2014). Feed-forward vs recurrent neural network models for non-stationarity modelling using data assimilation and adaptivity. *Hydrological Sciences Journal*, (i), 1–32.

Thiery, D., Bérard, P. & Camus, A. (1983). Captage de la source du Lez. Etude de relation entre la source et son réservoir aquifère - rapport n°1 : recueil des données et établissement d'un modèle de cohérence. BRGM Montpellier

Thiery, D., & Bérard, P. (1984). Alimentation en eau de la ville de Montpellier. Captage de la source du Lez étude des relations entre la source et son réservoir aquifère. Rapport n°3: modèle d'étude détaillé. BRGM Montpellier.

#### **Projet Lez GMU :**

Jourde, H., Dörfliger, N., Maréchal, J.-C., Batiot-Guilhe, C., Bouvier, C., Courrioux, G., Desprats, J.-F., Fullgraf, T., Ladouche, B., Leonardi, V., Malaterre, P.-O., Prié, V., Seidel, J.-L. (2011). Projet gestion multi-usages de l'hydrosystème karstique du Lez - Synthèse des connaissances récentes et passées. Rapport RP-60041-FR, 355pp.

Maréchal, J.-C., Borrell Estupina, V., Caballero, Y., Cernesson, F., Fleury, P., Jay-Allemand, M., Ladouche, B., Malaterre, P.-O. (2012). Projet gestion multi-usages de l'hydrosystème karstique du Lez. Simulations numériques de différents scénarios de changements globaux. Rapport RP-61050-FR, 235pp.

Borrell Estupina V., Maréchal J.-C., Coustau M., Fleury P., Jourde H., Kong A Siou L., Ladouche B., Malaterre P.-O., Mazzilli N., Ricci S. (2012) Projet gestion multi-usages l'hydrosystème karstique du Lez - Modèles numériques de fonctionnement de l'hydrosystème, Rapport RP-60222-FR, 253 pp.

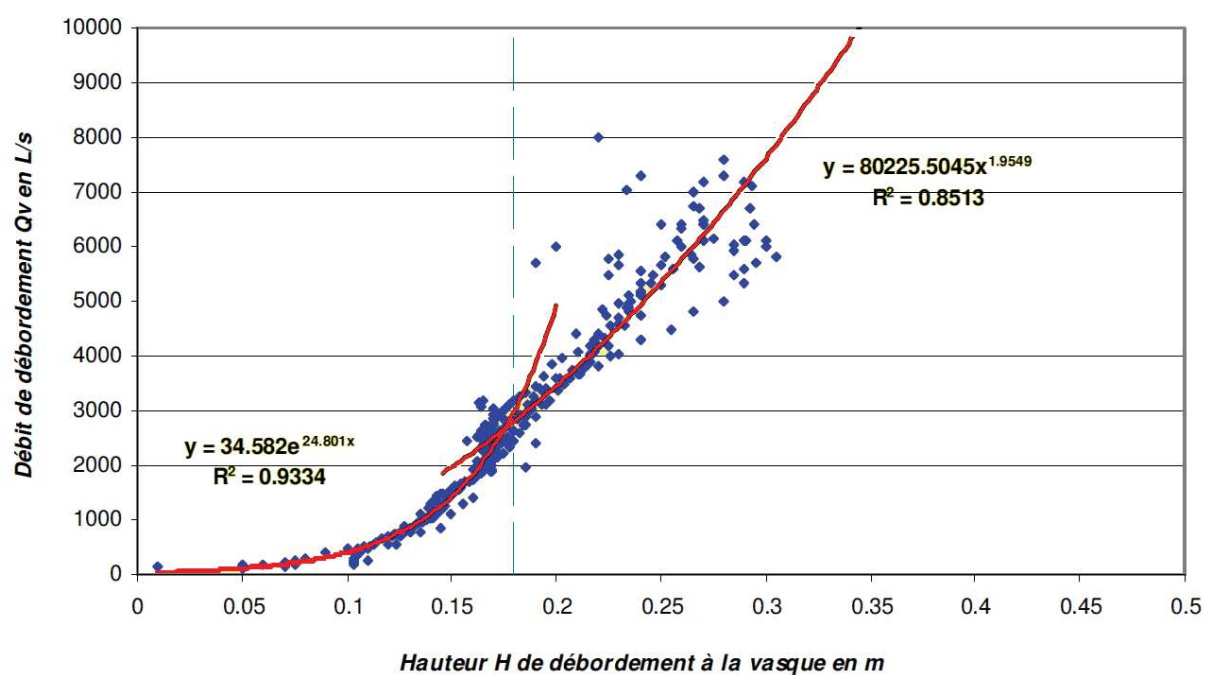
Leonardi, V., Jourde, H., Maréchal, J.-C. (2012). Projet gestion multi-usages de l'hydrosystème karstique du Lez - Résultats complémentaires des forages et traçages. Rapport final. BRGM/RP-61612-FR, 52 p.

#### **Observatoire MEDYCYSS :**


<http://www.medycyss.org/>, consulté le 15 novembre 2014.

Jourde, H., Batiot-Guilhe, C., Bailly-Comte, V., Bicalho, C., Blanc, M., Borrell, V., Bouvier, C., Boyer, J.F., Brunet, P., Coustau, M., Dieulin, C., Gayraud, E., Guinot, V., Hernandez, F., Kong-A-Siou, L., Johannet, A., Leonardi, V., Mazzilli, N., Marchand, P., Patris, N., Pistre, S., Seidel, J.L., Taupin, J.D., Van-Exter, S., (2011). The MEDYCYSS observatory, a Multi scale observatory of flood dYnamiCs and hYdrodynamicS in karSt (Mediterranean border southern France). In: *Advances in the Research of Aquatic Environment*. pp. 551–560.

# ANNEXE A : COURBE DE TARAGE ÉTABLIE SUR LE CYCLE 1962-1963 (D'APRÈS CONROUX, 2007)



# ANNEXE B : REPONSE IMPULSIONNELLE CALCULEE PAR CORRELATION CROISEE SUR L'ENSEMBLE D'ARRET (1959)



# ANNEXE C : RESUME DE LA CONTRIBUTION ORALE FAITE LORS DE LA 8EME CONFERENCE DE L'ASSOCIATION INTERNATIONALE DES GEOMORPHOLOGUES

Towards a better comprehension of rainfall-runoff relation in karst system at various time scales. Case study on the Lez aquifer (Southern France).

**Virgile TAVER<sup>(1,2)</sup>, Anne JOHANNET<sup>(1)</sup>, Valérie BORRELL<sup>(2)</sup>, Séverin PISTRE<sup>(2)</sup>, Marc Vinches<sup>(1)</sup>**

<sup>(1)</sup> Ecole des Mines d'Alès, 6 avenue de Clavières, 30319 Alès Cedex, France ; <sup>(2)</sup> Université Montpellier II, Hydrosociences Montpellier, Place E. Bataillon, 34095 Montpellier Cedex 5, France

Keywords: Karst, time scale, rainfall-runoff time series

Karst aquifers represent largest underground resources for fresh water around the world providing fresh water to 25% of the population [Ford and Williams, 2007]. They are still underexploited because of the difficulty to understand their behavior, they can thus be considered as promising water resource for the future [Bakalowicz, 2005]. Due to complex processes of formation, these geomorphologic systems are very heterogeneous in space. Such complexity provides various hydrological behaviors, at different time scales, associated with unsaturated or saturated zone.

Due to the difficulty in measuring physical parameters and capitalizing on physical properties of such complex systems, the systemic approach was preferred in this study in order to improve the knowledge about these aquifers. Following such approach, rainfall and runoff time series were considered as input-output signal of a complex system. In order to better apprehend the various behaviors operating at different time scale, the rainfall-runoff relation was studied at different time scales, by resampling signal at various dyadic time scales (2T; 4T; 8T; 16T; 32T, where T is the shortest sampling period). Resulting time series were studied using three approaches a) statistical description and normality tests of time series and their distribution, b) modeling rainfall-runoff relations using neural networks model (machine learning), c) time series analyses (correlation, spectral analysis...).

Applied to the *Lez* karst aquifer, which provides the city of Montpellier (400 000 inhabitants, Southern France) with fresh water [Fleury, 2008], these methods allow characterizing the behavior at each time scale providing thus tools to apprehend the response time of the aquifer in various conditions and its vulnerability to climate modification.

# ANNEXE D : RESUME DU POSTER PRESENTE LORS DE L'AGU FALL MEETING 2013

## Quantification of frequency-components contributions to the discharge of a karst spring.

VIRGILE TAVER<sup>(1,2)</sup>, ANNE JOHANNET<sup>(1)</sup>, MARC VINCHES<sup>(1)</sup>, VALERIE BORRELL<sup>(2)</sup>, SEVERIN PISTRE<sup>(2)</sup>, DOMINIQUE BERTIN<sup>(3)</sup>

(1) EMA, 6 av.de Clavières, 30319 Alès Cedex, France

(2) Université Montpellier 2, HSM, Place E. Bataillon, 34095 Montpellier Cedex 5, France.

(3) GEONOSIS, 51 place R. Tribes, 30140 St-Jean-du-Pin, France

Karst aquifers represent important underground resources for water supplies, providing it to 25% of the population. Nevertheless such systems are currently underexploited because of their heterogeneity and complexity, which make work fields and physical measurements expensive, and frequently not representative of the whole aquifer.

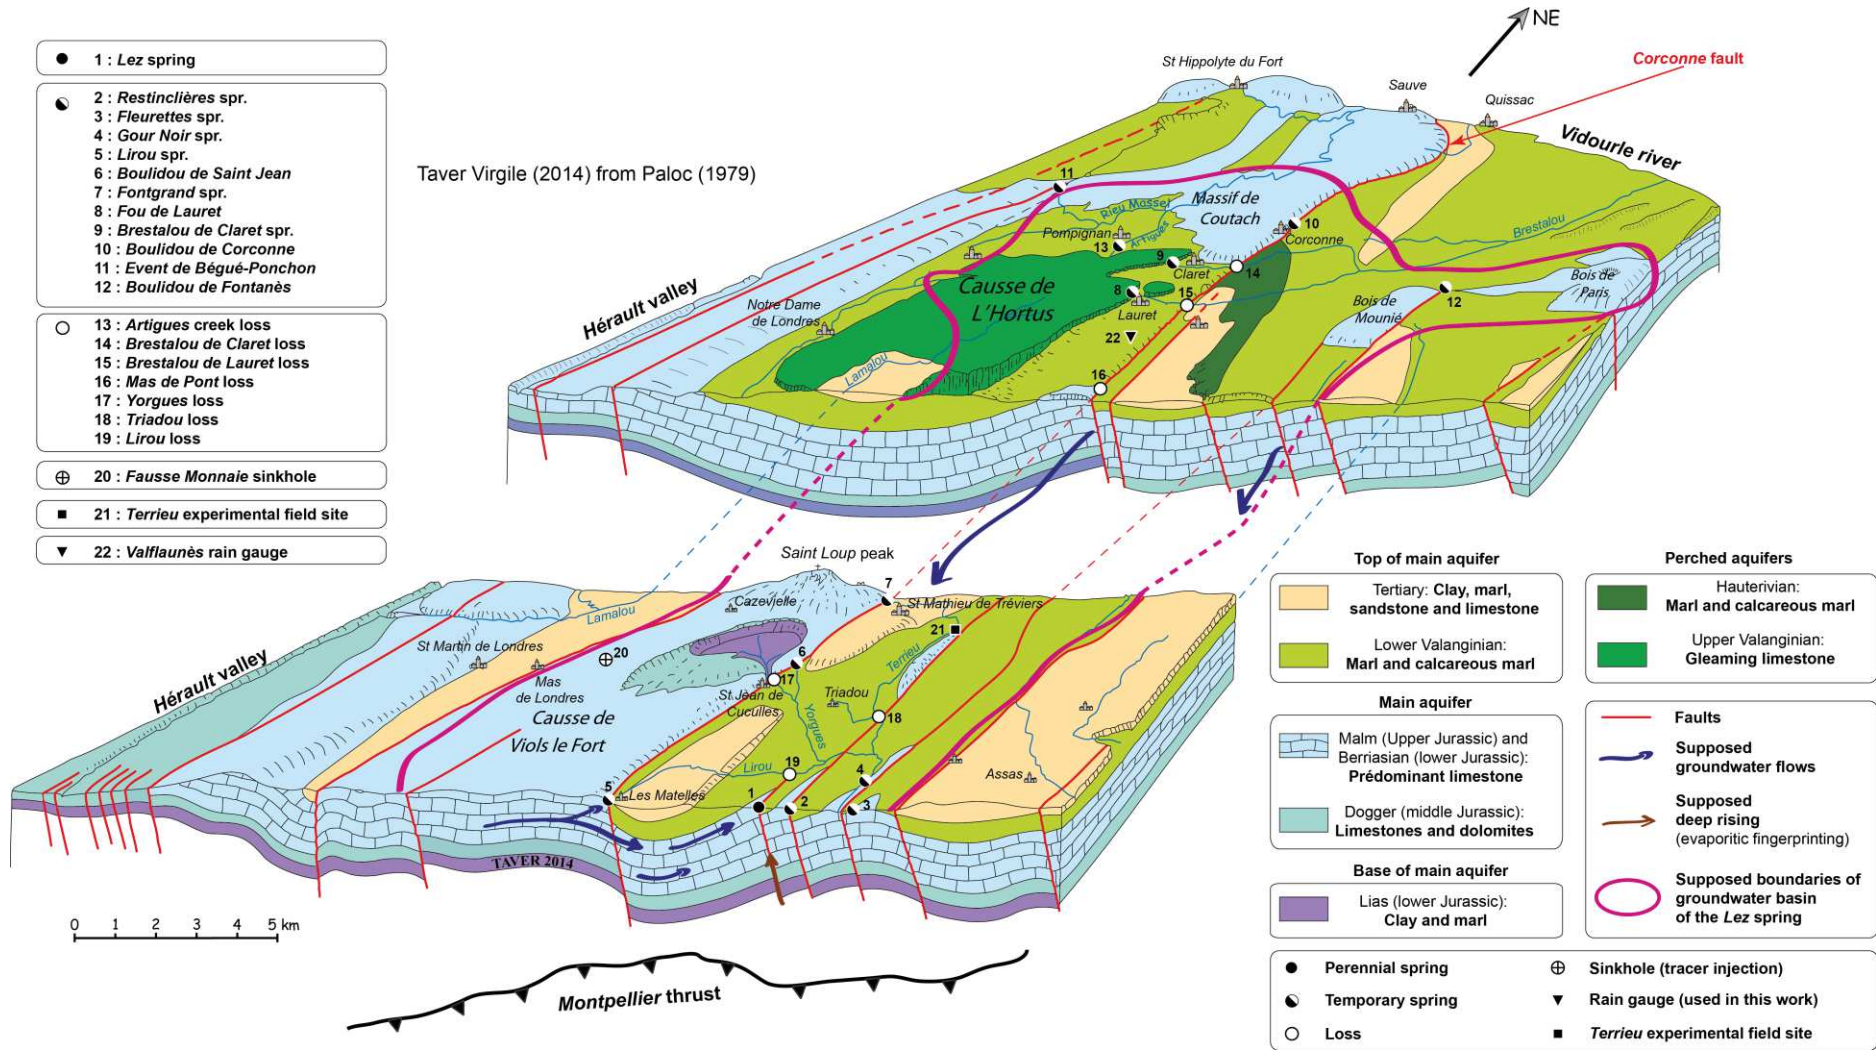
The systemic paradigm appears thus at a complementary approach to study and model karst aquifers in the framework of non-linear system analysis. Its input and output signals, namely rainfalls and discharge contain information about the function performed by the physical process. Therefore, improvement of knowledge about the karst system can be provided using time series analysis, for example Fourier analysis or orthogonal decomposition [1]. Another level of analysis consists in building non-linear models to identify rainfall/discharge relation, component by component [2].

In this context, this communication proposes to use neural networks to first model the rainfall-runoff relation using frequency components, and second to analyze the models, using the KnoX method [3], in order to quantify the importance of each component. Two different neural models were designed: (i) the recurrent model which implements a non-linear recurrent model fed by rainfalls, ETP and previous estimated discharge, (ii) the feed-forward model which implements a non-linear static model fed by rainfalls, ETP and previous observed discharges. The first model is known to better represent the rainfall-runoff relation; the second one to better predict the discharge based on previous discharge observations.

KnoX method is based on a variable selection method, which simply considers values of parameters after the training without taking into account the non-linear behavior of the model during functioning. An amelioration of the KnoX method, is thus proposed in order to overcome this inadequacy. The proposed method, leads thus to both a hierarchization and a quantification of the input variables, here the frequency components, over output signal.

Applied to the *Lez* karst aquifer, the combination of frequency decomposition and knowledge extraction improves knowledge on hydrological behavior. Both models and both extraction methods were applied and assessed using a fictitious reference model. Discussion is proposed in order to analyze efficiency of the methods compared to *in situ* measurements and tracing.

# ANNEXE E : ENGLISH VERSION OF FIGURE 24 (P 133)



Interpretative diagram of hydrogeological basin of the Lez spring. From Paloc (1979).







## RESUME

La connaissance du fonctionnement hydrodynamique des karsts représente un enjeu planétaire pour la ressource en eau car ils alimentent en eau potable près de 25% de la population mondiale. Néanmoins, la complexité, l'anisotropie, l'hétérogénéité, la non-linéarité et l'éventuelle non-stationnarité de ces aquifères en font des objets encore largement sous-exploités du fait de la difficulté de caractériser leur morphologie et leur fonctionnement hydrodynamique. Dans ce contexte, le paradigme systémique permet d'apporter de nouvelles méthodes en étudiant ces hydrosystèmes au travers de la relation entre leurs signaux d'entrée (pluie) et de sortie (débit).

La démarche proposée dans cette thèse consiste à utiliser un maximum d'informations, issues du terrain et des analyses systémiques, pour contraindre les modèles par réseaux de neurones. L'objectif est de les rendre interprétables en termes de processus hydrodynamiques en rapprochant le fonctionnement du modèle à celui du système naturel afin d'obtenir une bonne représentation et d'extraire des connaissances à partir des paramètres du modèle.

Ainsi ce travail porte sur l'association des informations disponibles sur l'hydrosystème avec les résultats des analyses corrélatoires et spectrales pour le développement d'une décomposition multirésolution temporelle ainsi que pour contraindre les modèles par réseaux de neurones. Une nouvelle méthode de sélection des variables, plus à même de représenter le fonctionnement hydrodynamique du système à long terme, a ainsi pu être proposée. Ces modèles contraints par l'information présentent de très bons résultats et offrent la possibilité, grâce à leurs paramètres, d'étudier la contribution temporelle des variables d'entrée à l'estimation de la sortie mesurée.

La modélisation des hydrosystèmes non-linéaires et non-stationnaires par réseaux de neurones a été enrichie par une implémentation originale de l'assimilation de données qui conduit à l'amélioration des performances. En effet, selon que les non-stationnarités concernent le bassin ou les forçages, l'assimilation a pu être respectivement utilisée pour modifier les paramètres ou les variables d'entrée des modèles.

La modification des variables d'entrées ouvre un champ d'application considérable puisque celle-ci peut être utilisée pour i) combler des lacunes ou encore homogénéiser des séries chronologiques, ii) estimer la pluie efficace.

Finalement, ces différentes méthodes d'analyse et de modélisation, essentiellement développées sur l'hydrosystème karstique du Lez, permettent d'améliorer la connaissance de la relation pluie-débit à différentes échelles temporelles. Ces outils méthodologiques offrent donc la perspective d'une meilleure gestion de l'aquifère tant en termes de crues que de ressource. L'avantage de ces outils d'analyse et de modélisation est qu'ils peuvent être transposés à d'autres systèmes.

## ABSTRACT

Improving knowledge of karst hydrodynamics represents a global challenge for water resources because karst aquifers provide approximately 25% of the world population in fresh water. Nevertheless, complexity, anisotropy, heterogeneity, non-linearity and possible non-stationarity of these aquifers make them underexploited objects due to the difficulty to characterize their morphology and hydrodynamics. In this context, the systemic paradigm proposes others methods by studying these hydrosystems through input-output (rainfall-runoff) relations.

The approach proposed in this thesis is to use information from field measurement and from systemic analyses to constrain neural network models. The goal is to make these models interpretable in terms of hydrodynamic processes by making model functioning to be similar to natural system in order to obtain a good representation and extract knowledge from model parameters.

This work covers the association of information available on the hydrosystem with correlation and spectral analyses to develop a temporal multiresolution decomposition of variables and to constrain neural network models. A new method for variable selection, adapted to represent long term hydrodynamics of the system, has been proposed. These constrained models show very good results and allow, through their parameters, to study the temporal contribution of inputs variables to the output.

Modeling nonlinear and non-stationary hydrosystems with neural network has been improved by a novel implementation of data assimilation. More precisely, when non-stationarity is attributed to the catchment, data assimilation is used to modify the model parameters. When the inputs are non-stationary, data assimilation can be used to modify the inputs.

The modification of inputs opens considerable scope to: i) fill gaps or homogenizing time series, ii) estimate effective rainfall.

Finally, these various analyses and modeling methods, mainly developed on the karst hydrosystem *Lez*, can improve the knowledge of the rainfall-runoff relationship at different time scales. These methodological tools thus offer perspectives of better management of the aquifer in terms of floods and resources. The advantage of these analyses and modeling tools is that they can be applicable to other systems.