

Modélisation des crues de bassins karstiques par réseaux de neurones. Cas du bassin du Lez (France)

Line Kong a Siou

▶ To cite this version:

Line Kong a Siou. Modélisation des crues de bassins karstiques par réseaux de neurones. Cas du bassin du Lez (France). Hydrologie. Université Montpellier II - Sciences et Techniques du Languedoc, 2011. Français. NNT: . tel-00649103

HAL Id: tel-00649103 https://theses.hal.science/tel-00649103

Submitted on 7 Dec 2011

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.



<u>THESE</u>

Présentée à l'Université de Montpellier II – Sciences et Techniques du Languedoc – Pour obtenir le grade de docteur

Spécialité : Hydrogéologie

École Doctorale : Systèmes Intégrés en Biologie, Agronomie, Géosciences, Hydrosciences et Environnement (SIBAGHE)

Modélisation des crues de bassins karstiques par réseaux de neurones. Cas du bassin du Lez (France)

Présentée et soutenue publiquement par

Line Kong A Siou

Le 21 octobre 2011

Directeur de thèse : M. Séverin Pistre

Jury

| M. Gérard Dreyfus | Rapporteur |
|------------------------------|----------------------|
| M. Alain Mangin | Rapporteur |
| Mme Nathalie Dörfliger | Examinatrice |
| M. Christian Leduc | Président du Jury |
| M. Séverin Pistre | Directeur de thèse |
| Mme Anne Johannet | Encadrante |
| Mme Valérie Borrell Estupina | Encadrante - Invitée |
| Mme Caroline Wittwer | Invitée |

« Du pied du col de la Furka jusqu'en Camargue, Des Pyrénées espagnoles jusqu'à Royan, De Saint-Germain source Seine jusqu'à Honfleur, Et du mont Gerbier-de-Jonc jusqu'à Saint-Nazaire Ainsi que de n'importe où à n'importe où, L'eau fait sans cesse la navette En n'étant chaque fois, comme a dit le poète, Ni tout à fait la même Ni tout à fait une autre. »

> Georges Brassens *Les Amoureux quí écrívent sur l'eau*

Remerciements

Cette thèse s'est déroulée au sein du Centre des Matériaux de Grande Diffusion de l'Ecole des Mines d'Alès. Je remercie Messieurs *Yannick Vimont* et *José-Marie Lopez-Cuesta*, successivement Directeurs de ce laboratoire pour m'y avoir accueillie. Pour mon accueil régulier au sein du laboratoire HydroSiences Montpellier, je tiens à remercier Monsieur Eric Servat qui en est le Directeur.

Je tiens à remercier Messieurs *Marc Vinches*, animateur de l'équipe Génie civil et hydrologie, et *Eric Garcia-Diaz*, responsable du pôle Matériaux et Structures du Génie Civil, pour leur soutien et leurs nombreux conseils.

Un grand merci à « l'équipe de choc » qui a encadré cette thèse et a permis son déroulement dans des conditions idéales. Merci pour leur soutien tant sur le plan professionnel que sur le plan personnel, et pour leurs encouragements. Je tiens à exprimer ma profonde reconnaissance à Monsieur *Séverin Pistre*, pour avoir dirigé ce travail en m'accordant confiance et disponibilité. Ses grandes qualités humaines, scientifiques et pédagogiques m'ont été précieuses pour effectuer ce travail. J'adresse mes plus chaleureux remerciements à mes encadrantes de proximité, Mesdames *Anne Johannet* et *Valérie Borrell Estupina*. Valérie, merci pour ton dynamisme et pour avoir, la première, pensé à moi pour ce travail de thèse. Ta connaissance dans la modélisation hydrologique a été une aide précieuse. Anne, merci pour ta disponibilité et ton soutien au quotidien. Tes compétences en réseaux de neurones ont été indispensables pour la bonne tenue de ce travail.

Je suis très honorée que Messieurs *Alain Mangin*, et *Gérard Dreyfus*, aient accepté d'être les rapporteurs de cette thèse, qu'ils en soient ici remerciés

Je remercie Madame *Nathalie Dörfliger*, pour l'intérêt qu'elle a porté à notre collaboration autour de ce projet, ainsi que pour avoir accepté d'examiner ce travail.

Je tiens à remercier Monsieur *Christian Leduc* pour l'intérêt qu'il a porté à ce travail et les remarques pertinentes formulées à l'occasion des différents comités de pilotage de cette thèse, ainsi que pour avoir accepté d'examiner ce travail.

Merci également à Monsieur *Pierre Roussel* et à Madame *Caroline Wittwer* pour les discussions intéressantes que nous avons pu avoir lors des comités de pilotages.

J'exprime ma profonde gratitude à Mademoiselle *Perrine Fleury*, pour l'intérêt qu'elle a porté à notre collaboration et les nombreuses simulations qu'elle a effectuées dans ce cadre. Je la remercie également pour m'avoir fourni tous les fichiers résultats nécessaires, me permettant ainsi de mieux apprécier les performances du modèle VENSIM et de les représenter le plus fidèlement possible dans ce travail.

Je tiens à remercier Monsieur *Henri Paloc* pour les discussions intéressantes que nous avons eues et pour m'avoir ouvert son impressionante bibliothèque. Je remercie également Monsieur *Michel Bakalowicz* pour m'avoir fait partager son savoir sur le karst du Lez.

Je remercie les personnes qui m'ont aidée à acquérir les données nécessaires à ce travail : Monsieur *Gilles LeGac* de la DIREN Montpellier m'a ouvert l'imposante base de données des débits et hauteurs d'eau du Lez et Madame *Catherine Hamet* de METEO FRANCE pour m'avoir facilité l'accès aux données pluviométriques. Je remercie également *Pascal Brunet* pour les précieuses informations qu'il a pu me fournir sur les données du Lez.

Je tiens à remercier chaleureusement les élèves de mini-mission de l'Ecole des Mines d'Alès et les stagiaires qui ont participé à cette étude, et particulièrement *Kevin Cros* pour son enthousiasme et la qualité du travail qu'il a fourni lors de son stage de Master 2.

Je tiens à remercier Monsieur *Dominique Bertin* de la société Géonosis pour le développement de RNFpro qui m'a permis d'effectuer toutes les simulations par réseaux de neurones.

Je remercie chaleureusement toutes les personnes qui ont facilité mes démarches administratives tout au long de ces trois années : *Sylvie Cruvellier* à Alès et *Catherine Marchand* à Montpellier. Merci également à l'équipe du garage à Alès pour avoir facilité mes déplacements réguliers à Montpellier et à l'équipe de la bibliothèque de l'Ecole des Mines d'Alès pour leurs précieux conseils dans la gestion des références bibliographiques et pour l'accès aux documents.

J'ai une pensée pour tous les doctorants, ex-doctorants et permanents rencontrés à Alès et à Montpellier et qui m'ont permis de travailler dans une ambiance chaleureuse : Audrey, Benjamin, Thomas, Mélissa, Léna, Vincent B., Vincent C., Vincent M., Arnaud, Olivier, Siska, Lucie, Nico P., Nico C-L, Maïmouna, Pierre-Erwan, Hossein, Denis, Serge et ceux que j'oublie. Je remercie spécialement Guillaume qui m'a fait profiter de ses connaissances en matière de météorologie. Merci également à Mathieu pour les intéressantes discussions que nous avons pu avoir au cours de ces trois années de thèse communes sur le Lez, et pour les moments de franche rigolade lors des quelques jaugeages que nous avons effectués ensembles. Merci à Cécile Baudry qui, lors de son passage en post-doc à Alès, m'a fait profiter sans compter de ses connaissances en mathématiques appliquées

Une mention spéciale pour mes compagnons de cordée et de navigation qui ont rendu possible les nécessaires escapades de fin de semaine : *Julien, Marie, Fred, Eugénie, Rava, Aurélie* et les autres « PKM boys and girls ».

Un grand merci à *Ludo*, mon « grand frère » et à toute sa petite famille, *Jessy, Marine, Lou* et *Alice* qui m'apportent soutien et réconfort dans chaque étape de ma vie depuis bien des années.

Je voudrais remercier particulièrement ma famille, et surtout mes parents *Didier* et *Christine* et ma sœur *Lucie* qui me soutiennent dans chacun de mes choix et m'ont encouragée à chaque fois que j'en avais besoin.

Enfin, merci à JC qui m'a chaque jour soutenue avec une infinie patience et affection.

Avertissement :

Les résultats de cette thèse ont été rédigés, pour la majorité, sous forme de publications scientifiques en anglais afin de permettre une meilleure diffusion de ce travail auprès de la communauté scientifique nonfrancophone.

Pour les lecteurs francophones, chaque article est néanmoins précédé d'une traduction française de son titre et de son résumé. Egalement, les points clés développés dans les articles et nécessaires à la compréhension de ce mémoire font l'objet d'un paragraphe en français situé à la suite de chaque article. Enfin, des compléments concernant les résultats développés dans les articles sont donnés à la suite des points clés lorsque cela est nécessaire.

Sommaire

| Liste des illustrations | 13 |
|--|---------------|
| Liste des tableaux | 15 |
| Résumé | 17 |
| Abstract | 19 |
| Introduction | 21 |
| Chapitre I : Approche systémique pour l'étude du karst | 23 |
| 1. Le karst : spécificités | 23 |
| 1.1. Définition | 23 |
| 1.2. Processus de karstification | 24 |
| 1.2.1. Dissolution de la roche | 24 |
| 1.2.2. Transport des matières dissoutes | 24 |
| 1.2.3. Organisation des écoulements et phases de karstification | 25 |
| 1.3.1. L'épikarst | 27 |
| 1.3.2. La zone non-saturée | 27 |
| 1.3.3. La zone saturée | 27 |
| 2. L'approche systémique | |
| 2.1. Méthodes d'étude du karst | 29 |
| 2.2. Méthode de caractérisation des karsts | 29 |
| 2.2.1. Corrélation simple et corrélation croisée | |
| 2.2.2. Analyse spectrale | |
| 2.2.3. Étude des débits classés | |
| 2.2.4. Décomposition en ondelettes | 36 |
| 2.3. Modélisation pluie-débit conceptuelle | 38 |
| 2.3.1. Généralités sur les modèles conceptuels pour les hydrosystèmes | karstiques 39 |
| 2.3.2. Modèles conceptuels appliqués aux karsts | 43 |
| 2.3.3. Conclusion sur les modèles conceptuels | 45 |
| 3. Conclusion du chapitre I | 46 |
| Chapitre II : L'apprentissage statistique pour l'identification des hydr | osystèmes 49 |
| 1. Présentation des réseaux de neurones | 49 |
| 1.1. Neurone formel | 49 |
| 1.2. Réseaux de neurones et architectures | 50 |
| 1.2.1. Les réseaux de neurones statiques | |
| 1.2.2. Les réseaux de neurones dynamiques | |
| 1.2.3. Apprentissage des réseaux dynamiques | |

| 1.3. | Le perceptron multicouche et ses propriétés | 54 |
|---------------|---|-------------------|
| | 1.3.1. Approximation universelle | 54 |
| | 1.3.2. Parcimonie | 54 |
| 2. A | pprentissage et sélection du modèle | |
| 2.1. | Règles d'apprentissage | 55 |
| | 2.1.1. Fonction de coût | 55 |
| | 2.1.2. Optimisation | 56 |
| | 2.1.3. Méthodes de second ordre | 56 |
| 2.2. | Problème du surajustement | 57 |
| | 2.2.1. Éléments clés compris dans l'article | 76 |
| 3. N | Iodélisation pluie-débit | |
| 3.1. | Perceptron multicouche pour simuler et prévoir le débit | 78 |
| 3.2. | Modélisation fonctionnelle des systèmes karstiques | 79 |
| 3.3. | Au-delà de la boîte noire | 80 |
| | 3.3.1. Introduire des connaissances a priori | 80 |
| | 3.3.2. Accéder à des informations « cachées » | 81 |
| 4. C | onclusion du Chapitre II | |
| <u>Chapit</u> | re III : Le Lez, un système karstique complexe | 85 |
| 1. P | résentation générale du bassin | |
| 1.1. | Géographie et hydrographie | |
| | 1.1.1. Climat : des épisodes pluvieux intenses | 85 |
| | 1.1.2. Hydrographie | |
| 1.2. | Exploitation de la source du Lez | |
| 2. C | ontexte géologique et hydrogéologique | |
| 2.1. | Lithologie et contexte tectonique | |
| 2.2. | Hydrogéologie et karstification | 95 |
| | 2.2.1. Phases de karstification | 95 |
| | 2.2.2. Hydrogéologie | 95 |
| | 2.2.3. Instrumentation du bassin et interprétation des séries chronologiqu | es 100 |
| 3. C | aractérisation et modèles existants de l'aquifère du Lez | 106 |
| 3.1. | Caractérisation de l'aquifère du Lez par l'approche systémique | 106 |
| | 3.1.1. Analyse des débits classés | 106 |
| | 3.1.2. Corrélogrammes simples et croisés | 108 |
| | | |
| | 3.1.3. Conséquence du pompage en « gestion active » | 111 |
| 3.2. | 3.1.3. Conséquence du pompage en « gestion active » Travaux de modélisation à la source du Lez | ¹¹¹ |
| 3.2. | 3.1.3. Conséquence du pompage en « gestion active » Travaux de modélisation à la source du Lez 3.2.1. Modélisation à la source du Lez : un historique | 111 112 112 |

| | 3.2.3. Modèle VENSIM | 114 |
|-------------------|---|-------------|
| 4. Co | onclusions | 117 |
| Chapit | re IV : Modélisation par réseaux de neurones de la relation pluie | -débit à la |
| source | du Lez | |
| 4 54 | élection de variables et célection de la complexité du réseau de neur | 0000 110 |
| 1. 50 | Péquiné | 120 |
| 1.1. | Élémente clés compris dans l'article | 120 |
| 1.2. | 1.2.1 Máthode combináe de sélection des entráes | 140 |
| 12 | En complément à l'article | 140 1/16 |
| 1.5. | 1 3 1 Prévision du débit à la source du Lez | 146 |
| ۍ د | omparaison de deux approches pour la simulation des débits et de la | niézométrie |
| à la s | source du Lez | |
| 2.1. | Caractéristiques du modèle neuronal et du modèle à réservoir | |
| | 2.1.1. Le modèle conceptuel VENSIM | |
| | 2.1.2. Le modèle neuronal | 152 |
| | 2.1.3. Description des variables | |
| 2.2. | Simulation du débit journalier à la source | 158 |
| | 2.2.1. Variable pluie brute pondérée | 158 |
| | 2.2.2. Variable pluie efficace | |
| | 2.2.3. Variable pluie brute pondérée et « évapotranspiration artificielle » | » 162 |
| | 2.2.4. Conclusions sur la simulation pluie-débit | 163 |
| 2.3. | Simulation de la piézométrie | 164 |
| | 2.3.1. Variable pluie pondérée (r _{pond}) | 165 |
| | 2.3.2. Variable pluie efficace (r_{eff}) | 167 |
| | 2.3.3. Variables pluie pondérée et évapotranspiration «artificielle » | 167 |
| | 2.3.4. Conclusion sur la simulation de la piézométrie | |
| 3. Co | onclusion sur la modélisation de l'hydrosystème du Lez par réseaux d | de neurones |
| 17 | 0 | |
| <u>Chapit</u> | <u>re V : Au-delà de la boîte noire, la méthode KnoX (Knowledge eX</u> | traction) |
| pour l'e | étude du karst par réseaux de neurones | 173 |
| ı. In | troduction | |
| 2. U [.] | tilisation de la géologie pour la modélisation hydrodynamique d'un a | quifère |
| kars | tique par réseaux de neurones. Cas de la source karstique du Lez (Su | d de la |
| Fran | ce) | 174 |
| 3. Co | onclusion sur l'étude du karst par réseaux de neurones | 199 |

| Conclusion | 201 |
|---|----------|
| Références bibliographiques | 203 |
| Glossaire | 215 |
| Annexe A : Interprétation des corrélogrammes | 217 |
| Annexe B : Méthode de Levenberg-Marquardt | 221 |
| Annexe C : Modélisation hydrodynamique des karsts par réseaux de neurones | <u>:</u> |
| comment dépasser la boîte noire ? | 223 |

Liste des illustrations

| Figure 1 : Affleurement de calcaire karstifié (le cahier donne l'échelle) et conduit de la so | ource |
|---|--------|
| du Lirou, de plusieurs mètres de large (Karst du Lez) | 24 |
| Figure 2 : Schéma figuratif d'un karst jurassien et d'un karst vauclusien | 25 |
| Figure 3 : Organisation du réseau en fonction de la variation du niveau de base | 26 |
| Figure 4 : Schéma fonctionnel du karst d'après A. Mangin (1998) | 28 |
| Figure 5 : Corrélogramme simple du débit à la source du Lez pour le cycle hydrolog | gique |
| 01/09/2002-31/08/2003 | 31 |
| Figure 6 : Exemple de corrélogramme croisé pluie-débit | 32 |
| Figure 7 : Exemple de courbe des débits classés. Débits de la source du Lez | 35 |
| Figure 8 : Spectre en ondelettes continues du signal de débit de la source du Lez s | ur la |
| période 1987-1999 (communication personnelle A. Mangin) | 38 |
| Figure 9 : Représentation schématique d'un neurone formel | 50 |
| Figure 10 : Exemple de réseau de neurones non-bouclé | 51 |
| Figure 11 : Exemple de réseau de neurones bouclé ou récurrent | 52 |
| Figure 12 : Modèle postulé récurrent | 52 |
| Figure 13 : Modèles postulés et modèle neuronal associé pour les deux hypothèses : bru | iit de |
| sortie et bruit d'état | 53 |
| Figure 14 : Perceptron multicouche à une couche de neurones cachés | 54 |
| Figure 15 : Sous-ensembles de validation | 76 |
| Figure 16 : Modèle boîte transparente. | 81 |
| Figure 17 : Exemple de modèle "boîte transparente" | 83 |
| Figure 18 : Hydrographie, bassin versant topographique | 87 |
| Figure 19 : Tête de forage dans l'usine souterraine d'exploitation de la source du Lez | 88 |
| Figure 20 : Schéma du dispositif du captage de la source du Lez | 89 |
| Figure 21 : Canal de restitution du débit réservé | 89 |
| Figure 22 : Débordement de la vasque de la source du Lez. | 90 |
| Figure 23 : Source du Lez à sec au mois de Juillet 2011. | 90 |
| Figure 24 : Vasque de la source du Lez à sec et anciennes installations de pompage | 90 |
| Figure 25 : Log géologique et hydrogéologique schématique de l'aquifère des garrigues n | nord- |
| montpelliéraines d'après G. Marjolet et J. Salado (1976) et P. Bérard (1983) | 92 |
| Figure 26 : Coupe schématique générale du bassin du Lez d'après M. Bonnet et M. Mat | tauer |
| (2010) | 93 |
| Figure 27 : Carte géologique simplifiée du bassin du Lez | 94 |
| Figure 28 : Source du Lirou à sec en Juin 2010. | 96 |
| Figure 29 : Fonctionnement hydrodynamique supposé, d'après P. Bérard (1983) | 97 |
| Figure 30 : Coupe hydrogéologique simplifiée de l'aquifère du Lez d'après P. Fleury | et al. |
| (2008) | 98 |
| Figure 31 : Forages sur le site expérimental du Terrieu | 99 |
| Figure 32 : Instrumentation du bassin d'alimentation du Lez | 101 |
| Figure 33 : Seuil de mesure de hauteurs d'eau de la DIREN en aval de la source du Lez | 102 |

| Figure 34 : Courbe de tarage et jaugeages à la station de mesure de débits Lez | de la source du 102 |
|--|--------------------------|
| Figure 35 : Indices centrés réduits des séries chronologiques de pluie et de 2004. | e débit de 1988 à 103 |
| Figure 36 : Mesure piézométrique et volume journalier pompé à la source du | 1 Lez 105 |
| Figure 37 : Courbes de débits classés par période de prélèvement à la sourc | e du Lez d'après |
| Y. Conroux (2007) modifiées avec l'accord du BRGM. | |
| Figure 38 : Corrélogramme simple du débit moyen sur la période 1988-200 |)5 à la source du |
| Lez | |
| Figure 39 : Corrélation croisée entre les cumuls de pluies à Prades-le-Lez | et les cumuls de |
| pluie journalières à Saint-Martin-de-Londres pour le cycle hydrolo | gique 1988-1989. 109 |
| Figure 40 · Corrélogramme croisé pluie à Saint-Martin-de-Londres/débit à | la source du Lez |
| pour le cycle hydrologique 2003-2004 | 110 |
| Figure 41 : Corrélation croisée pluje à Saint-Martin-de-Londres/Débit à l | a source du Lez |
| pour l'évènement pluvieux de Décembre 2003 | 111 |
| Figure 42 · Organisation générale du modèle d'après P. Fleury <i>et al.</i> (2008) | 116 |
| Figure 43 · Simulation du débit à la source du Lez par le modèle VENSIM | 117 |
| Figure 44 : Débits simulés à la source du Lez | 147 |
| Figure 45 : Débits prévus à la source du Lez à un horizon de prévision de un | iour |
| Figure 46 : Débits prévus à la source du Lez à un horizon de prévision de de | 110 |
| Figure 47 : Débits prévus à la source du Lez à un horizon de prévision de tro | ois jours |
| Figure 48 : Modèle VENSIM 2a. | |
| Figure 49 : Modèle VENSIM 2b. | |
| Figure 50 : Perceptron multicouche non dirigé et comprenant le débit pompé | en entrée 153 |
| Figure 51 : Pluviomètres et pondération déterminée par TEMPO. | 155 |
| Figure 52 : Evapotranspiration artificielle sinusoïdale et gaussienne normalis | sées |
| Figure 53 : Pluje brute, pluje efficace et évapotranspiration potentielle calcu | lée et artificielle. |
| | |
| Figure 54 : Hydrogrammes simulés à partir de la pluie pondérée calculée | par TEMPO sur |
| l'ensemble de test | |
| Figure 55 : Hydrogrammes simulés à partir de la pluie efficace calculée | par TEMPO sur |
| l'ensemble de test | 161 |
| Figure 56 : Hydrogrammes simulés à partir de la pluie pondérée et de l'év | vapotranspiration |
| artificielle sur l'ensemble de test. | |
| Figure 57 : Débit pompé et piézométrie à la source du Lez pour l'année civile | 2003 |
| Figure 58 : Piézométrie simulée à partir de la pluie pondérée sur l'année de t | est 2003 166 |
| Figure 59 : Piézométrie simulée à partir de la pluie efficace sur l'année de tes | t 2003 167 |
| Figure 60 : Piézométrie simulée à partir de la pluie pondérée et de l'év | apotranspiration |
| artificielle sur l'année de test 2003 | |
| | |

Liste des tableaux

| Tableau 1 : Evènements pluvieux les plus intenses de la base de données 104 |
|--|
| Tableau 2 : Moyenne des corrélations croisées pluie-pluie pour tous les cycles hydrologiques |
| de 1988 à 2004109 |
| Tableau 3 : Moyenne sur 15 évènements des corrélations maximales pluie-débit à la source |
| du Lez |
| Tableau 4 : Contributions de chaque secteur du bassin d'alimentation de la source du Lez en |
| fonction du niveau piézométrique dans le drain principal de la source selon Y. |
| Karam (1989) |
| Tableau 5 : Critères de Nash pour différents modèles et horizons de prévision 147 |
| Tableau 6 : Critères de persistance pour différents modèles et horizons de prévision 147 |
| Tableau 7 : Coefficients de Nash obtenus pour la simulation du débit journalier à la source |
| du Lez par le modèle VENSIM et par le modèle par réseaux de neurones, en |
| fonction de la chronique de pluie utilisée163 |
| Tableau 8 : Pourcentage du pic principal de débit obtenu pour la crue de décembre 2003 à la |
| source du Lez par le modèle VENSIM et par le modèle par réseaux de neurones, en |
| fonction de la chronique de pluie utilisée163 |
| Tableau 9: Coefficients de Nash obtenus par les deux modèles pour la simulation de la |
| piézométrie, en fonction de la chronique de pluie utilisée |
| Tableau 10 : Dimensionnement des réseaux de neurones pour la simulation de la pluie et de |
| la piézométrie |

Les karsts sont l'une des formations aquifères les plus présentes au monde. Exploités, ils fournissent de l'eau potable pour près de 25% de la population mondiale. Cependant la forte hétérogénéité de leur structure implique un comportement non-linéaire particulièrement difficile à simuler et à prévoir.

Les réseaux de neurones formels sont des modèles d'apprentissage statistique qui ont été largement utilisés en hydrologie de surface depuis les années 1990, grâce à leurs propriétés de parcimonie et d'approximation universelle.

Dans cette thèse, il est proposé d'utiliser les réseaux de neurones pour étudier le comportement des aquifères karstiques. L'aquifère du Lez est choisi pour appliquer le modèle par réseaux de neurones. Cet aquifère, situé près de l'agglomération de Montpellier (400 000 habitants), est exploité pour fournir de l'eau potable à une grande partie de l'agglomération.

Dans un premier temps, un réseau de neurones « classique », de type boîte noire, est appliqué à la simulation et à la prévision des débits de la source du Lez. Une méthode de sélection des entrées de pluie est proposée, couplant analyse par corrélations croisées et méthode de validation croisée. Les résultats montrent l'adéquation du modèle neuronal pour la simulation et la prévision du débit de la source d'un aquifère karstique complexe. Le test du modèle est effectué sur les deux cycles hydrologiques comportant les crues les plus intenses de la base de données. Les hydrogrammes montrent que le modèle neuronal a été capable de correctement prévoir les débits des crues majeures en test, qui sont supérieurs aux débits présents dans la base d'apprentissage du modèle. La prévision est acceptable jusqu'à un horizon de prévision de un jour.

Dans un second temps, une méthode d'extraction des données contenues dans la boîte noire est proposée. Afin de contraindre le modèle neuronal à donner des valeurs physiquement interprétables, des connaissances *a priori* sur la géologie de l'aquifère sont incluses dans l'architecture du réseau de neurones. La méthode KnoX (Knowledge eXtraction) proposée dans cette étude permet d'extraire du modèle les contributions des différentes zones géologiques à la source du Lez ainsi que les temps de réponse correspondants. L'application de la méthode KnoX à un hydrosystème fictif dont on contrôle en particulier les temps de réponse et contributions des différents sous-hydrosystèmes fictifs a permis de valider cette méthode.

Les résultats obtenus sur le bassin du Lez sont très satisfaisants et en adéquation avec les connaissances actuelles que l'on a sur ce système. De plus la méthode a permis d'affiner ces connaissances, notamment l'infiltration retardée par des aquifères perchés et les limites du bassin d'alimentation de la source du Lez. Enfin, la méthode KnoX est générique et applicable à tout hydrosystème pour lequel on dispose de mesures de pluie et de débit.

MOTS CLES : KARST, MODELISATION HYDRODYNAMIQUE, RESEAUX DE NEURONES, LEZ, CRUE

Abstract

Karst is one of the most widespread aquifer formations in the world. Their exploitation provides fresh water to practically 25% of the global population. The high level of structure heterogeneity in these aquifers however makes them complex and their behavior is difficult to study, simulate and forecast.

Artificial neural networks are machine learning models widely used in surface hydrology since the 90's thanks to their properties of parsimony and universal approximation.

In this thesis, artificial neural networks are used to study karst aquifer behavior. Application is done on the *Lez*. This aquifer situated near Montpellier conurbation (400 000 inhabitants) provides fresh water for a large part of this population.

First, a "classical" black box neural network is applied to simulate and forecast *Lez* spring discharge. A rainfall input selection method is proposed, using cross correlation analysis and cross validation method at the same time. Results show neural model efficiency in order to simulate and forecast the spring discharge of a complex karstic aquifer. The model was tested using two hydrologic cycles including the two most intense floods of the database. Hydrographs shows that neural model was able to forecast correctly the maximum flood discharge of these intense floods when they are higher than all discharges of the learning database. Forecasting is satisfactory until a one-day horizon.

In a second time, extraction of the knowledge included in the black box is proposed. In order to constrain the model to provide physically plausible solution, *a priori* knowledge about aquifer geology is included into the network architecture. KnoX (Knowledge eXtraction) method proposed in this study aims at extract geological zone contributions to the *Lez* spring and corresponding response times. The KnoX methodology was applied to a fictitious hydrosystem built using a model with controlled parameters, in particular contributions of subbasin to the outlet and lag time of each subbasin. This application permitted to validate the KnoX methodology.

Results obtained on the *Lez* basin are satisfactory and agree with current knowledge about this hydrosystem. In addition, the KnoX methodology allows refining this knowledge, in particular concerning delayed infiltration because of infiltration in perched aquifer and concerning *Lez* spring alimentation basin boundaries. Lastly the KnoX methodology is a generic methodology that can be applied on any basin with available discharge and rainfall data.

KEY WORDS : KARST, HYDRODYNAMIC MODELING, NEURAL NETWORKS, LEZ, FLOOD

Introduction

Les karsts sont l'une des formations aquifères les plus présentes au monde, fournissant de l'eau potable pour quasiment un quart de la population mondiale. Pourtant, leur grande hétérogénéité de structure implique un fonctionnement complexe et fortement non-linéaire, difficile à appréhender. Dans ces conditions, la problématique de la gestion des ressources en eau d'origine karstique est posée. De plus, de récentes études sur les karsts méditerranéens ont montré que le karst pouvait jouer un rôle majeur lors des crues de surfaces qui peuvent, dans cette région, causer des dégâts considérables. On peut citer par exemple l'épisode du Var en 2010 qui a causé 25 morts et 600 millions d'euros de dommages directs.

Considérant les crues catastrophiques observées ces dernières années (Vaison-la-Romaine 1992, Nîmes 1988, Gardons 2002) qui ont causé des pertes humaines et des dégâts importants, le ministère français chargé du développement durable a créé en 2003 le SCHAPI (Service Central d'Hydrométéorologie et d'Appui à la Prévision des Inondations) qui est responsable d'un service d'alerte mis en place sur internet : *vigicrue*. Le présent travail a été réalisé en collaboration avec le SCHAPI. En proposant de simuler et d'anticiper la réponse en débit d'un hydrosystème karstique à sa source (exutoire), ce travail de thèse permet d'améliorer la simulation et la prévision pluie-débit sur les bassins de type karstique.

Le karst du Lez qui est le sujet de cette étude fait l'objet d'attentions particulières car il est situé à proximité immédiate de l'agglomération de Montpellier (Hérault), qui compte près de 400 000 habitants. Il est de plus exploité par un pompage au niveau de son exutoire principal, la source du Lez, pour fournir de l'eau potable à une large partie de cette agglomération.

Les deux principales difficultés qui font obstacle à la modélisation des aquifères karstiques sont la grande hétérogénéité du milieu, issue de son histoire tant géologique que climatique, et le comportement non linéaire qui en résulte. Si les moyens géophysiques sont actuellement impuissants pour décrire dans le détail la structure et les réseaux de drainages du système souterrain, de même les outils méthodologiques n'ont pas encore atteint le degré de maturité qui leur permettrait de proposer des modèles et outils généralisables, ou même opérationnels.

Face à ce besoin, ce travail de thèse présente une nouvelle méthode d'investigation des aquifères karstiques, et en particulier de l'aquifère du Lez, utilisant les réseaux de neurones formels. Grâce à leurs propriétés de parcimonie et d'approximation universelle, les réseaux de neurones ont été largement utilisés en hydrologie de surface, et notamment en prévision des crues, depuis une vingtaine d'années. Ils sont le plus souvent considérés comme des modèles de type boîte noire ne permettant pas de comprendre le système modélisé. Ce travail propose une méthode d'extraction des connaissances contenues dans la boîte noire afin de la rendre « transparente », permettant ainsi d'approfondir la connaissance du système modélisé.

La première partie de ce mémoire présente les fondamentaux concernant les karsts, les difficultés rencontrées pour les étudier et les modéliser. L'approche systémique pour l'étude des karsts sera présentée. Cette approche propose d'assimiler le karst à un *système* dont seules les entrées et les sorties sont connues. Le traitement de ces données d'entrée et de sortie (c'est-à-dire de pluviométrie et de mesure du débit), notamment par des méthodes empruntées au domaine du traitement du signal, permet de caractériser le fonctionnement du système. Plusieurs modèles

issus de cette approche seront présentés avec leurs caractéristiques et les résultats qu'ils ont obtenus sur des aquifères karstiques.

La seconde partie concerne les réseaux de neurones utilisés pour la modélisation pluie-débit. Leur fonctionnement et leurs propriétés fondamentales seront explicités. Le problème majeur de ces modèles, le dilemme biais-variance qui conduit au surajustement sera présenté, ainsi que les méthodes permettant de l'éviter. Des applications de réseaux de neurones à l'identification de la relation pluie-débit seront proposées, ainsi que des applications concernant les karsts.

Dans le troisième chapitre, l'hydrosystème karstique du Lez sera présenté. L'exploitation particulière en « gestion active » de l'exutoire principal de l'aquifère, la source du Lez, sera abordée ainsi que les particularités géologiques et hydrodynamiques qui font de cet aquifère un système complexe au fonctionnement difficile à appréhender. Différentes études visant à simuler le fonctionnement de l'aquifère, et notamment le débit de la source du Lez, seront synthétisées.

Les résultats de l'application de modèles systémiques au karst du Lez sont présentés dans le quatrième chapitre. La comparaison est effectuée entre le modèle neuronal que nous avons proposé et le modèle VENSIM, développé au BRGM. Le modèle VENSIM est un modèle à réservoirs, approche plus classique en hydrogéologie, qui a spécialement été développé pour des karsts et a déjà été appliqué au karst du Lez. La comparaison porte à la fois sur la simulation du débit à la source du Lez et sur la simulation de la piézométrie dans le drain principal conduisant à cette source.

Ce chapitre nous permet de mettre en évidence l'adéquation de l'outil choisi, les réseaux de neurones, à la simulation du fonctionnement des aquifères karstiques. La prévision des débits de la source du Lez est ainsi effectuée et validée sur l'événement le plus intense de toute la base d'apprentissage, prouvant ainsi que les réseaux de neurones peuvent être capables de généraliser à des événements rares ou extrêmes.

Enfin, le dernier chapitre s'attache à présenter une méthode permettant l'extraction des connaissances sur le système physique étudié, grâce à une architecture particulière du réseau de neurones qui inclut des connaissances *a priori* sur le système. Dans ce travail, ce sont les connaissances sur la géologie du système qui sont mises à profit pour construire un réseau comportant quatre sous-réseaux, représentant chacun un sous-bassin d'alimentation de la source du Lez. La méthode KnoX (Knowledge eXtraction) développée dans ce travail permet d'extraire du réseau les contributions des différents sous-bassins ainsi que leurs temps de réponse respectifs. Ces informations n'étant pas mesurables sur le terrain, une méthode de validation utilisant un hydrosystème fictif a également été mise en place.

Chapitre I : Approche systémique pour l'étude du karst

Ce premier chapitre a pour objectif de présenter le karst, aquifère particulier de par son mode de formation et son fonctionnement. Le premier paragraphe définit le karst, son mode de formation, sa structure et son fonctionnement hydrodynamique, soulignant notamment l'hétérogénéité de structure de ce type d'aquifère, qui conduit à un fonctionnement qui peut être fortement non-linéaire. Pour ces raisons, l'étude des karsts est particulièrement difficile, comparée à l'étude d'autres types d'aquifères.

La seconde partie de ce chapitre sera consacrée aux méthodes permettant la caractérisation d'un karst à partir de l'analyse des séries chronologiques de pluie et de débit, en utilisant l'approche systémique. Cette approche considère le karst comme un système qui transforme un signal d'entrée en un signal de sortie. L'étude de la transformation de pluie en débit permet alors de connaître les caractéristiques fonctionnelles du système, c'est-à-dire du karst.

Nous nous intéresserons ensuite à la modélisation du système « karst ». L'identification de la relation pluie-débit permet de proposer une modélisation du système, permettant de simuler à partir des données chronologiques de pluie, la chronique des débits sortants du karst. Nous verrons que ce modèle peut également être mis à profit pour identifier des propriétés physiques du système.

1. Le karst : spécificités

1.1. Définition

Un karst est le résultat du travail érosif de l'eau dans un massif carbonaté. La dissolution des carbonates créant des vides, drains et grottes, pouvant être de grande taille, il en résulte un système très hétérogène permettant le stockage et la circulation d'importantes quantités d'eau. Selon D. Ford et P. Williams (2007), un karst est un terrain au paysage et à l'hydrologie particuliers qui nécessite à la fois la présence d'une roche très soluble et d'une importante perméabilité^{*1} secondaire (fractures). Ces deux facteurs permettent d'obtenir une perméabilité tertiaire, formée par l'infiltration de l'eau dans les fractures préexistantes, et qui facilitera à terme la majorité des écoulements. Le processus de karstification, responsable de l'apparition de cette perméabilité tertiaire, sera explicité au paragraphe suivant. Les vides présents au sein du karst sont de tailles très variables, microscopiques (<10⁻⁴m) pour les pores de la roche elle-même (porosité matricielle), et jusqu'à des conduits de grande taille (>10²m). Cette forte hétérogénéité structurale implique un comportement hydrodynamique complexe.

¹ Les * marquent les termes définis dans le glossaire en fin de document



Figure 1 : Affleurement de calcaire karstifié (le cahier donne l'échelle) et conduit de la source du Lirou, de plusieurs mètres de large (Karst du Lez).

1.2. Processus de karstification

L'organisation des écoulements dans le karst est conditionnée par le processus de karstification, qui est responsable de la formation de vides de grandes taille, et par les réseaux de vides préexistants qui peuvent être d'origine tectonique (failles), ou provenir d'une karstification antérieure. Ces vides, infimes soient-ils, sont indispensables pour assurer la circulation de l'eau qui va permettre d'amorcer le processus de karstification; aussi l'agencement des réseaux préexistants a-t-il une grande influence sur la géométrie du réseau karstifié. Le processus de karstification résulte de deux phénomènes : la dissolution de la roche et le transport des matières dissoutes.

1.2.1. Dissolution de la roche

La dissolution implique d'importantes quantités de carbonates, elle est considérée comme appartenant au processus de karstification si l'absence de la roche dissoute modifie sensiblement les conditions d'écoulement (M. Bakalowicz, 1996). Pour que la dissolution soit importante, il est nécessaire que l'eau ait un caractère acide, permettant d'augmenter la solubilité des carbonates. A titre d'exemple, les carbonates ont une solubilité de seulement 50 mg/l dans de l'eau en équilibre avec l'atmosphère contre 300 mg/l après avoir traversé un sol et s'être chargée en CO₂. L'acidification se fait par dissolution de CO₂ ou d'autres acides minéraux qui doivent être présents en grande quantité. L'hydrogène sulfuré (H_2S) par exemple peut être présent en quantité suffisante, d'autant qu'il est 2,5 fois plus soluble dans l'eau que le CO₂. L'acidification par dissolution de CO₂ reste la plus fréquente. Le CO₂ provient de l'atmosphère, du sol ou plus rarement du dégazage du manteau* qui peut survenir dans des régions tectoniquement actives. De plus, la solubilité du CO₂ augmente lorsque la température de l'eau diminue ce qui permet le développement d'une karstification en altitude ou dans des régions froides.

1.2.2. Transport des matières dissoutes

Le transport des matières dissoutes ou en suspension est toujours soumis à la gravité qui est généralement le principal moteur du transport de matière. Mais à ce gradient hydraulique*

s'ajoutent les gradients chimiques et thermiques qui peuvent jouer un rôle non négligeable. Dans les deux derniers cas, le mouvement d'eau est provoqué par la différence de densité des eaux.

Pour illustrer le cas d'un gradient chimique, on peut citer l'exemple des aquifères littoraux qui sont soumis à une intrusion d'eau salée. Le contact entre l'eau douce et l'eau salée en milieu poreux a une géométrie régulière et bien connue (biseau salé*) mais dans le cas du karst, dans lequel les écoulements se font par des fractures et des conduits, ce contact est perturbé, si bien que l'eau salée peut se trouver au-dessus de l'eau douce, créant une instabilité et des mouvements d'eau de façon à rétablir l'équilibre.

Les mouvements dus à des différences de température sont observés dans les karsts hydrothermaux, où les différences de températures sont suffisamment importantes pour provoquer des mouvements de convection.

1.2.3. Organisation des écoulements et phases de karstification

La dissolution de la roche par l'eau permet aux écoulements de s'auto-organiser pour être drainés vers les exutoires du karst. En fonction de la genèse de l'aquifère karstique, les écoulements s'organisent différemment et donnent naissance à un karst de type jurassien ou vauclusien (Figure 2). Dans le cas d'un karst de type jurassien, les écoulements sont organisés au-dessus du niveau de l'exutoire, alors que dans un karst de type vauclusien, les écoulements s'organisent, au moins en partie, en profondeur, sous le niveau de l'exutoire*. Dans ce dernier cas les écoulements se font majoritairement en charge par des conduites forcées.



Système jurassien

Système vauclusien

Figure 2 : Schéma figuratif d'un karst jurassien et d'un karst vauclusien

Comme les conditions de karstification apparaissent de façon ponctuelle dans le temps et l'espace, on observe des phases de karstification, étroitement liées aux variations du niveau de base*. En effet, si par exemple le niveau de base s'abaisse, alors que les conditions de karstification sont réunies, un nouveau réseau karstique se développe, organisant les écoulements de façon à ce qu'ils rejoignent un exutoire qui sera situé plus bas que le niveau karstique précédent. Un nouveau réseau se forme donc, en dessous du niveau précédent qui deviendra probablement inactif ou ne pourra s'activer qu'en cas de crues (Figure 3). Les sources du niveau supérieur pourront alors fonctionner comme sources de trop-plein*.



Figure 3 : Organisation du réseau en fonction de la variation du niveau de base

Inversement, si le niveau de base s'élève, le nouveau réseau karstique se développera au dessus du précédent. Il faut noter que le développement d'un réseau karstique est rapide à l'échelle des temps géologique. Selon T. Atkinson *et al.* (1973), M. Bakalowicz (1975) et W. Dreybrodt (1998), cités par M. Bakalowicz (2005), il peut être de l'ordre de quelques dizaines de milliers d'années lorsque les conditions de karstification sont réunies.

De par le principe même de la karstification, les aquifères karstiques ont donc la propriété d'évoluer. On peut ainsi se représenter les karsts évoluant entre deux pôles extrêmes : un pôle non karstifié, c'est-à-dire uniquement fissuré (mais possédant un potentiel de karstification) et un pôle très karstifié. Chaque karst a donc une structure unique et susceptible d'évoluer dans le temps, dépendant notamment de l'importance de la karstification qu'il a subie, de la géologie et du climat dans lequel il se trouve. A cette structure unique s'associe un fonctionnement propre qui empêche souvent de généraliser à un karst ce que l'on a pu observer sur un autre. Cette spécificité augmente encore la difficulté de l'étude des karsts.

Contrairement à d'autres types d'aquifère, il n'est pas possible de définir un volume élémentaire représentatif (V.E.R.*) qui permet de décrire le fonctionnement du système à une plus petite échelle avant de l'élargir à l'aquifère entier. Le karst doit être considéré dans son ensemble. Néanmoins, le karst peut être séparé en grands ensembles ayant des formes et des fonctions différentes. Ceci fait l'objet du paragraphe suivant.

1.3. Structure géologique et fonctionnement hydrodynamique

Une hétérogénéité supplémentaire existe au sein du karst. Il est en effet généralement possible de distinguer plusieurs parties en fonction de leur position verticale et de leur fonction dans l'organisation des écoulements et du stockage.

Deux parties sont à considérer : la zone non-saturée et la zone noyée, auxquelles s'ajoute éventuellement un épikarst. Les paragraphes qui suivent décrivent les principales caractéristiques de chaque partie ainsi que leur rôle dans le fonctionnement hydrodynamique du karst. Ces informations sont synthétisées sur la Figure 4.

1.3.1. L'épikarst

L'épikarst, lorsqu'il est présent, est la partie la plus superficielle du karst, et paradoxalement la moins bien identifiée. A. Klimchouk (2004) a dénombré douze définitions de l'épikarst dans la littérature, tenant compte de plusieurs paramètres comme la structure de l'épikarst, sa localisation, son origine, son rôle hydrogéologique et morphogénique. L'épikarst est généralement défini comme une zone à forte porosité*: 5 à 10%, et pouvant mesurer jusqu'à plusieurs mètres d'épaisseur (M. Bakalowicz, 1996 ; A. Klimchouk, 2004). Le transfert de l'eau y est essentiellement vertical, il alimente la zone non-saturée puis la zone saturée.

L'épikarst correspond à une zone d'échanges privilégiés entre la surface, le sol et le karst luimême. C'est là que pourra être produit le CO₂ permettant l'acidification de l'eau qui s'infiltre dans le karst (M. Bakalowicz, 2005). Il peut également être capable de stocker de l'eau et ainsi constituer une nappe disponible pour l'évapotranspiration ou encore constituer un intermédiaire entre la surface et le stockage souterrain (zone saturée), qui peut permettre de protéger la ressource en eau souterraine, en retardant les eaux de surface potentiellement polluées. Enfin, dans certains cas, le stockage dans l'épikarst peut même être prépondérant devant le stockage dans la zone saturée (R. Lastennet et J. Mudry 1997; C. Perrin *et al.*, 2003).

1.3.2. La zone non-saturée

Dans la zone non saturée, encore appelée zone d'infiltration, la porosité est généralement moins importante que dans l'épikarst : 1 à 2% environ (M. Bakalowicz, 1996 ; A. Mangin, 1998). Dans le cas général, cette zone est une zone de transition entre la surface, ou l'épikarst s'il existe, et la zone noyée.

Cette zone est le siège, à la fois d'écoulements monophasiques et d'écoulements diphasiques (M. Bakalowicz, 2008). Les premiers sont des écoulements de type ruissellement, opérant dans les fissures et les conduits. L'écoulement diphasique (écoulement d'un mélange d'eau et d'air) quant à lui opère dans les micro-fissures. À ce niveau, une évacuation de l'eau sous forme gazeuse est possible. De plus, ceci implique de fortes variations de la perméabilité en fonction de la variation de la proportion air-eau dans ces fissures. Dans de rares cas, la zone non saturée peut jouer un rôle important dans le stockage de l'eau et donc pour le soutien des étiages. C'est par exemple le cas pour le karst de Notre-Dame des Anges (Vaucluse, France) sur lequel R. Lastennet et J. Mudry (1997) ont mené une étude de la chimie des eaux et ont montré qu'en automne, 66 à 75% de l'eau à l'exutoire provient de la zone non-saturée.

1.3.3. La zone saturée

La zone saturée, ou encore zone noyée est généralement la zone pour laquelle l'organisation des écoulements et des vides est la plus forte, avec une porosité pouvant aller jusqu'à 15% (A. Mangin, 1998).

La circulation de cette eau se fait généralement, non plus majoritairement verticalement, mais de façon sub-horizontale, permettant ainsi le drainage de l'eau vers l'exutoire, une source ou un groupe de sources karstiques. Les drains peuvent s'organiser à un niveau proche du niveau piézométrique* (voir piézométrie) dans le cas d'un karst de type jurassien, ou bien à grande profondeur dans le cas d'un karst de type vauclusien (Figure 2).

Par ailleurs, si le stockage d'eau dans la zone saturée est admis par la plupart des auteurs, l'organisation des écoulements et du stockage dans cette zone reste discuté. Il y a principalement deux façons de représenter son fonctionnement. L'une a été présentée par A. Mangin (1975) et l'autre par C. Drogue (1974). Pour A. Mangin (1975), le stockage se fait dans des vides, connectés aux conduits, appelés *systèmes annexes au drainage*. Pour C. Drogue (1974), c'est la porosité matricielle qui fait office de stockage. L'aquifère est donc vu comme un ensemble de blocs séparés par des conduits. Dans les deux cas, les unités de stockage (systèmes annexes ou matrice) se remplissent lors des crues puis se vident lors des étiages. Ainsi les conduits alimentent les systèmes annexes/matrice lors des hautes eaux et à l'inverse ce sont les systèmes annexes/matrice qui alimentent les conduits en étiage, permettant aux sources karstiques d'être pérennes. A. Mangin (1975) a mis en évidence ce processus à l'aide d'essais de traçages et d'une étude hydrochimique effectués sur le karst du Baget (Ariège).



Figure 4 : Schéma fonctionnel du karst d'après A. Mangin (1998).

Le schéma fonctionnel présenté en Figure 4 propose une représentation *systémique* du karst en prenant en compte les différents éléments de structure et de fonctionnement donnés dans ce paragraphe. La pluie entrant dans le système est transformée en débit, à la sortie de celui-ci, par un ensemble de processus représentés par des boîtes (infiltration lente, rapide, drain...).

2. L'approche systémique

Les paragraphes précédents ont montré que la principale caractéristique du karst est sa grande hétérogénéité, ce qui complique considérablement l'étude, à la fois du fonctionnement et de la structure du karst. Comme il est pratiquement impossible de déterminer avec précision la

structure d'un aquifère karstifié dans les trois dimensions de l'espace, l'étude du fonctionnement de l'aquifère ne peut donc se fonder sur une représentation spatiale fiable de celui-ci.

Sur ce constat, d'autres approches visant à étudier le fonctionnement du karst ont vu le jour, prenant en compte le karst dans sa globalité, sans chercher à en détailler le fonctionnement au niveau spatial.

Les données importantes, pour tout karst que l'on souhaite étudier, sont les mesures de pluviométrie et les mesures de débit sortant des sources karstiques. C'est-à-dire les données d'entrées et de sortie du *système karstique*. C'est de cette analogie entre karst est système que naît l'approche systémique pour l'étude du karst que l'on se propose de décrire dans ce chapitre.

2.1. Méthodes d'étude du karst

Comme le décrit la Figure 4, que nous avons commentée au paragraphe précédent, le karst comprend plusieurs fonctions différentes (infiltration rapide, lente, stockage...), il correspond donc à un assemblage de fonctions qui forment un système. C'est ce qu'a proposé A. Mangin (1975). L'approche systémique considère donc que les mesures d'entrée et de sortie contiennent toute l'information nécessaire pour comprendre le fonctionnement global de ce système.

Le système est assimilé à un opérateur permettant de passer d'un signal d'entrée à un signal de sortie. Afin de mieux appréhender les caractéristiques fonctionnelles du système on propose donc des méthodes d'analyse des signaux d'entrée et de sortie, ou des modèles permettant la simulation du débit à partir de la pluie sans pour autant connaître *a priori* la structure de ce dernier.

2.2. Méthode de caractérisation des karsts

L'étude des séries chronologiques de pluie et de débit permet d'obtenir des informations sur les caractéristiques fonctionnelles du système : le stockage, le temps de réponse, la vidange, ou encore la présence d'autres exutoires ou de trop-pleins.

Ce paragraphe présente les principales méthodes utilisées et les résultats qu'elles peuvent permettre d'obtenir. Nous commençons par les méthodes les plus classiques, introduites par A. Mangin (1975) et reprises par B. Marsaud (1997) : corrélations simples et croisées, analyse spectrale, et débits classés. Ensuite sont décrites les méthodes d'analyse en ondelettes développées par D. Labat *et al.* (2001). Des exemples d'applications illustrent les méthodes présentées et mettent en évidence que même si ces méthodes nécessitent une connaissance minimale de l'hydrosystème karstique, tout élément supplémentaire apporté à la connaissance de l'hydrosystème étudié permet de rendre les interprétations plus précises et plus proches de la réalité physique.

2.2.1. Corrélation simple et corrélation croisée

Corrélation simple

Les calculs de corrélation linéaire ont été adaptés par A. Mangin (1975) à partir de M. Jenkins et D. Watts (1968). Ils permettent de calculer la corrélation linéaire d'une série chronologique par rapport à la même série décalée dans le temps, cette corrélation notée r_k est calculée comme suit :

$$r_{k} = \frac{c_{k}}{s_{x}s_{x}}$$
Équation 1
$$C_{k} = \frac{1}{n}\sum_{i}^{n-k}(x_{i} - \bar{x}).(x_{i+k} - \bar{x})$$
Équation 2

Avec k le décalage en jours, x la chronique de débit, \bar{x} sa moyenne et S_x son écart-type. n est le nombre de jours que comporte la chronique considérée.

Le graphique représentant le vecteur \mathbf{r} des corrélations en fonction du décalage k est le corrélogramme simple (Figure 5). Il est symétrique par rapport à l'axe des ordonnées, il est donc inutile de le représenter pour les décalages négatifs.

Appliqué au signal de débit, le corrélogramme simple permet de déterminer l'*effet mémoire* d'un système. Défini par A. Mangin (1975), l'effet mémoire est le nombre de jours nécessaires pour atteindre le minimum d'autocorrélation permettant de considérer que celle-ci est négligeable. Il représente l'inertie du système. Connaître l'effet mémoire c'est connaître la durée maximale pour laquelle le débit est corrélé à lui-même. Pour déterminer la valeur de corrélation à laquelle correspond l'effet mémoire, A. Mangin (1975) a calculé l'erreur sur l'estimation du coefficient de corrélation C_k, se basant sur M. Jenkins & D. Watts (1968). Les détails de ce calcul sont présentés en annexe A. Cependant, compte tenu de certaines hypothèses statistiques qui ne sont pas toujours vérifiables, et pour simplifier, dans les différentes études menées sur l'autocorrélation du débit, l'effet mémoire est défini comme la durée nécessaire pour que l'autocorrélation atteigne la valeur de 0,2 (A. Mangin, 1981; A. Mangin, 1984; M. Larocque *et al.*, 1998), c'est donc cette valeur qui sera utilisée dans ce travail.

Un effet mémoire court signifie que le système réagit rapidement à la pluie ; on peut en déduire que le karst est bien karstifié, sans possibilités importantes de stockage. C'est le cas par exemple pour le karst d'Aliou, dans les Pyrénées dont l'effet mémoire est de seulement 4 jours. A l'inverse, l'exemple du karst de Fontestorbes, dans les Pyrénées également, présente un effet mémoire long (60 jours dans cet exemple) et peut traduire la présence de réserves importantes (A. Mangin, 1984).



Figure 5 : Corrélogramme simple du débit à la source du Lez pour le cycle hydrologique 01/09/2002-31/08/2003

Corrélogramme croisé

La corrélation croisée s'applique à deux séries chronologiques distinctes (ici la pluie et le débit). Elle permet d'étudier la corrélation entre ces deux séries, en fonction du décalage de ces deux séries dans le temps. Le calcul qui permet d'aboutir au *corrélogramme croisé*, pendant du corrélogramme simple, est très ressemblant au calcul effectué en corrélation simple et se décompose comme suit :

$$r_{k} = \frac{c_{k}}{s_{x}s_{y}}$$

$$Equation 3$$

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

$$Equation 4$$

Avec k le décalage en jours, x la chronique de débit et y la chronique de pluviométrie, et S_x , S_y les écart-types correspondants. n est le nombre de jours que comportent les deux chroniques considérées

Le corrélogramme croisé obtenu représente la corrélation en fonction du décalage temporel entre les deux séries (Figure 6). On ne considère que les décalages positifs car ils correspondent à la configuration d'un système causal (la pluie détermine le débit). Le corrélogramme pluie-débit permet d'appréhender la corrélation entre la pluie et le débit. Ainsi, le pendant de l'effet mémoire pour le corrélogramme simple permet de déterminer la durée de décalage à partir de laquelle les deux séries sont indépendantes, c'est-à-dire la taille de l'historique de pluviométrie influençant le débit. La corrélation seuil choisie est la même que pour l'effet mémoire : 0,2. La Figure 6 présente un exemple de corrélogramme croisé pluie débit et son effet mémoire.



Figure 6 : Exemple de corrélogramme croisé pluie-débit.

Applications des analyses corrélatoires

Depuis que les méthodes corrélatoires ont été proposées, elles ont été appliquées par de nombreux auteurs. On peut citer les travaux de L. Eisenlhor et al. (1997) qui ont cherché à établir une validation des méthodes de corrélations simples et croisées. Pour ce faire, L. Eisenlhor et al. (1997) ont conçu un modèle numérique de karst 2D puis 3D leur permettant de simuler des débits selon des paramètres bien connus et ensuite d'appliquer à cette chronique les méthodes d'analyse corrélatoire. Pour l'auteur la problématique principale de ce type de méthode provient justement du fait qu'elles prennent en compte un système très global : la relation pluie-débit dépendant d'une multitude de paramètres, il est parfois difficile d'interpréter les résultats obtenus en termes de caractéristiques bien précises, qu'elles soient hydrodynamiques ou structurales. L'étude menée avec le modèle numérique montre que la forme du corrélogramme dépend non seulement de l'importance de la karstification et de la densité de drainage* du karst, informations que l'on cherche généralement à approcher, mais aussi de la proportion entre l'écoulement rapide et l'écoulement de base, de la fréquence des évènements pluvieux au cours de la période considérée et du type d'infiltration auquel le système est soumis (infiltration diffuse ou concentrée*). Les auteurs déduisent donc qu'il est nécessaire d'avoir des connaissances hydrogéologiques sur le système étudié avant de proposer des interprétations concernant les caractéristiques structurelles et hydrodynamiques de ce système.

L'utilisation de données spatialisées de débit, piézométrie, pluie et conductivité a permis de mettre en évidence une forte hétérogénéité spatiale sur l'aquifère étudié. Plus précisément les corrélogrammes croisés ont permis d'identifier des temps de réponses différents pour les parties Sud et Nord du karst. De plus, ces méthodes appliquées aux données de piézométrie et de conductivité ont permis d'identifier des comportements différents selon l'état de saturation des conduits.

2.2.2. Analyse spectrale

Le calcul de la densité spectrale de puissance, ou spectre, d'un signal permet de décrire ce signal dans le domaine des fréquences. En théorie, l'analyse spectrale repose sur la stationnarité du signal à étudier. Dans le cas idéal d'un signal stationnaire*, le signal de sortie peut être décomposé en une somme de sinusoïdes déphasées affectées de coefficients reliés à la puissance de l'harmonique considérée dans le signal. Dans le cas des karsts l'analyse peut être conduite dans un but de description de propriétés fréquentielles des signaux de pluie et de débit (A. Mangin 1984).

Même s'il est clair que les précipitations, et par voie de conséquence, les débits ne sont pas stationnaires, l'objectif de l'analyse spectrale est alors d'identifier des phénomènes périodiques dans le cas d'une analyse simple, et d'observer les transformations appliquées au signal d'entrée par le système, dans le cas d'une analyse croisée.

Analyse simple

La densité spectrale de puissance d'un signal est obtenue, grâce au théorème de Wiener-Khinchine, en effectuant la transformée de Fourier de l'autocorrélation du signal comme suit (A. Mangin, 1984):

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

Équation 5

Comme pour l'analyse corrélatoire, k est le décalage en jours, f est la fréquence, r_k est le coefficient de corrélation du signal à analyser défini au paragraphe précédent et D_k est une fenêtre de pondération qui limite l'impact sur le calcul du fait que l'observation du signal est d'une durée finie. m est la troncature et doit être inférieur au nombre de mesures du signal analysé divisé par trois (A. Mangin, 1984).

La comparaison des spectres d'entrée et de sortie d'un système, c'est-à-dire de pluie et de débit pour un système hydrologique, permet d'obtenir des informations sur la façon dont le système filtre le signal d'entrée. Appliqué à la chronique de débit, le calcul du spectre permet d'obtenir le *temps de régulation,* défini par A. Mangin (1984) comme la durée d'influence du signal d'entrée ; ce dernier est l'inverse de la largeur de la bande passante*, c'est-à-dire l'inverse de la fréquence pour laquelle la densité spectrale de puissance a perdu la moitié de sa puissance maximale.

A. Mangin (1984) a utilisé cette méthode sur trois systèmes karstiques présentant des caractéristiques hydrogéologiques différentes (karstification plus ou moins développée, importance du stockage...). L'analyse des chroniques de pluie a été conduite parallèlement à celle des chroniques de débit. Les spectres des débits montrent tous l'existence d'une périodicité annuelle qui n'est pas observée sur les spectres des pluies. A. Mangin en conclut que la cyclicité est donc introduite par le système karstique, en particulier par sa fonction de stockage. De plus, l'analyse spectrale présente des cycles plus prononcés pour le système comportant *a priori* le plus de réserves en eau, comparativement aux deux autres qui ont peu ou pas de réserves. Ceci signifie que l'analyse spectrale a pu mettre en évidence une périodicité dans les débits, due au stockage de l'eau dans les aquifères karstiques. Il est donc intéressant de noter que le filtrage opéré par le système karstique a mis en évidence des variations annuelles peu visibles sur les précipitations, mais plus perceptibles sur les débits.

Équation 6

Analyse croisée

Il s'agit cette fois d'étudier le spectre croisé pluie-débit. De la même façon que pour le spectre simple, le spectre croisé est la transformée de Fourier du corrélogramme croisé pluie-débit et s'écrit de la façon suivante (décomposition en partie réelle et partie imaginaire):

$$S_{xy}(f) = h_{xy}(f) - i\lambda_{xy}(f)$$

Avec:

$$h_{xy}(f) = 2 \left[r_{xy}(0) + \sum_{k=1}^{m} \left(r_{xy}(k) + r_{yx}(k) \right) D(k) \cos(2\pi f k) \right]$$
 Équation 7
$$\lambda_{xy}(f) = 2 \left[r_{xy}(0) + \sum_{k=1}^{m} \left(r_{xy}(k) + r_{yx}(k) \right) D(k) \sin(2\pi f k) \right]$$
 Équation 8

Où k est le décalage introduit pour l'analyse corrélatoire, r_{xy} et r_{yx} sont les coefficients de corrélation tels que décrits au paragraphe 2.2.1.2. concernant l'analyse corrélatoire croisée, f est la fréquence, D est la fenêtre de pondération introduite au paragraphe précédent. m est la troncature est doit être inférieure au nombre de mesures du signal analysé divisé par trois (A. Mangin, 1984).

Le déphasage entre le signal d'entrée et le signal de sortie est calculé ainsi :

$$\theta_{xy}(f) = \arctan\left(\frac{\lambda_{xy}(f)}{h_{xy}(f)}\right)$$
Équation 9

La fonction de gain donnée ci-après permet de déterminer si, pour l'harmonique considérée, la puissance a été amplifiée (g>1) ou atténuée (g<1) par le système.

$$g_{xy}(f) = \frac{S_{xy}(f)}{S_x(f)}$$
 Équation 10

Dans le cas d'un système karstique, le gain peut être relié au stockage de l'eau en hautes-eaux, puis à son écoulement en basses-eaux (M. Larocque *et al.* 1998). Par exemple la composante basse fréquence de l'écoulement correspondant au débit d'étiage est beaucoup plus importante dans le signal de débit que dans le signal de pluie qui est un signal très variable.

2.2.3. Étude des débits classés

Les courbes de débits classés se construisent en rangeant les débits par classe d'amplitude et en calculant pour chaque classe la probabilité empirique de non-dépassement associée. Les classes sont représentées sur l'axe des abscisses, et les probabilités empiriques sur l'axe des ordonnées, les deux axes sont en échelle logarithmique pour pouvoir visualiser des valeurs très différentes. Ceci permet également d'identifier des segments de droites utilisés par la suite pour interpréter le graphique (voir l'exemple Figure 7). Cette représentation permet d'identifier des évènements particuliers (mise en fonctionnement de trop-plein*, fuite vers un autre système...). Ces fonctionnements étant généralement répétitifs, le rangement par classe permet de mettre en évidence les débits anormalement faibles ou élevés.



Figure 7 : Exemple de courbe des débits classés. Débits de la source du Lez

L'interprétation du graphique est effectuée en repérant les anomalies sur la courbe des débits classés.

Les anomalies de fonctionnement correspondent aux ruptures de pentes observées. Dans sa thèse, B. Marsaud (1997) détaille les différentes interprétations possibles en fonction de ces variations (Table 1).

La Figure 7 présente la courbe des débits classés du Lez sur la période 1949-1968. Les segments de droites ajustés à la courbe ont des pentes notées α_i . Plus les débits sont forts, plus la pente de la droite est forte ($\alpha_1 < \alpha_2 < \alpha_3 < \alpha_4$). Comme cela est indiqué dans la Table 1, l'augmentation de la pente peut mettre en évidence la mise en fonctionnement de trop-pleins. Dans le cas du Lez plusieurs sources de débordement sont connues et expliquent donc les ruptures observées pour les débits forts.
| Pente des droites | Position de la rupture | Interprétation |
|---------------------------------|---------------------------|---|
| $\alpha_2 > \alpha_1$ | Forts pourcentages | - Mise en fonctionnement de trop-plein |
| | | - Fuites vers un autre système |
| | | - Stockage momentané |
| | | - Fuites ou débordement de la station de |
| | | jaugeage lors des hautes-eaux |
| α ₂ < α ₁ | | - Apports en provenance d'un autre système |
| | | - La station de jaugeage prend compte lors des |
| | | crues des écoulements n'appartenant pas au |
| | | système |
| $\alpha_2 > \alpha_1$ | Faibles | - Constitution d'une réserve |
| $\alpha_2 < \alpha_1$ | pourcentages | - Apport d'une réserve issue d'un cycle antérieur |
| $\alpha_2 > \alpha_1$ | Double rupture | - Piégeage d'une réserve lors de la décrue et |
| $\alpha_3 < \alpha_2$ | | restitution au cours du tarissement |

Table 1 : Interprétation des ruptures de pente dans les courbes de débits classés (B. Marsaud 1997).

N. Dörfliger *et al.* (2008) ont appliqué les méthodes d'analyse corrélatoire, spectrale et de débits classés à une chronique de débit naturels à la source du Lez, afin de mettre en évidence l'impact de l'exploitation de la source sur l'aquifère. Les débits classés ont montré une amélioration de la circulation de l'eau dans l'aquifère pour des débits à la source supérieur à 2 m³/s. A l'inverse l'effet mémoire aurait diminué par rapport à la période non-influencée par l'exploitation de l'aquifère. Globalement, l'aquifère du Lez apparaît donc comme plus transmissif. Les auteurs expliquent cette modification dans le fonctionnement hydrodynamique par le décolmatage*, dû au pompage effectué à la source, de conduits jusqu'alors colmatés par des sédiments.

2.2.4. Décomposition en ondelettes

Comme nous l'avons suggéré précédemment, l'analyse spectrale s'applique aux signaux stationnaires, or les signaux hydrologiques sont par nature non stationnaires du fait des variations saisonnières ou climatiques, ainsi que par l'anthropisation de ces systèmes. Afin de disposer d'une méthode permettant d'analyser les signaux non stationnaires, l'analyse en ondelette est effectuée, comme par exemple pour identifier les effets d'un pompage (D. Labat *et al.* 1999), ou de l'intermittence d'une source (D. Labat *et al.* 1999). À la différence de l'analyse de Fourier, les fréquences identifiées dans le signal sont localisées temporellement. La transformée en ondelette décompose le signal en une famille d'ondelettes translatées et dilatées. Une ondelette est une fonction oscillante de moyenne nulle. L'ondelette mère est notée ψ . Plusieurs types d'ondelettes mères existent, D. Labat *et al.* (1999) dans leur étude sur les karsts pyrénéens en ont utilisé plusieurs, et ont conclu que les résultats étaient très peu sensibles au choix de l'ondelette analysante, dans le cas d'une analyse avec un pas de temps journalier.

La famille d'ondelettes s'obtient en dilatant et en translatant l'ondelette mère selon la formule suivante :

$$\psi_{u,s} = \frac{1}{\sqrt{s}}\psi\left(\frac{t-u}{s}\right) \qquad \qquad \acute{Equation 11}$$

Les paramètres u et s permettent respectivement de contrôler la translation et la dilatation (ou échelle) de l'ondelette ψ .

La transformée en ondelettes d'une fonction x(t) au temps u et à l'échelle s s'écrit :

$$Wx(u,s) = \int_{-\infty}^{+\infty} x(t) \frac{1}{\sqrt{s}} \psi^*\left(\frac{t-u}{s}\right) dt \qquad \qquad \acute{Equation 12}$$

ce qui correspond au produit de convolution de la fonction x(t) avec l'ondelette $\psi_{u,s}$.

Ondelettes discrètes

La transformation d'un signal peut également se faire en temps discret. Le temps discret est alors noté k et les paramètres u et s sont respectivement notés q et j.

Dans le cas discret, si l'on considère que les échelles varient également de manière discrète par puissance de 2 (selon une échelle dyadique), la dilatation et la translation de l'ondelette mère se fait de la façon suivante :

$$\psi_{j,q}(k) = a_0^{\frac{j}{2}} \psi(a_0^j k - q) \qquad \qquad \acute{Equation 13}$$

où $a_0=2$ est une constante correspondant à la plus petite échelle, *j* est la puissance donnant les variations d'échelles dyadiques et *q* le paramètre de retard. L'avantage de la transformée en ondelettes discrètes est que la décomposition du signal peut se faire sur une base d'ondelettes orthogonales les unes par rapport aux autres, tant en translation qu'en dilatation (échelle). Pour cela on décompose récursivement le signal en deux composantes : l'allure générale du signal (basses fréquences), appelée approximation, et le résidu du signal (hautes fréquences), appelé détail (D. Labat *et al.* 2000).

Grâce à l'orthogonalité des ondelettes discrètes, la transformée en ondelettes inverse peut être écrite de manière exacte. Lorsque l'on écrit la transformée inverse, le signal x(k) est donc exprimé comme une somme pondérée sur la base d'ondelettes ; cette écriture permet d'effectuer l'analyse multirésolutions (D. Labat *et al.* 2000).

Graphique et interprétation

Les transformées en ondelettes sont représentées sur des graphiques indiquant en abscisse le temps (mois, années ...) et en ordonnées l'échelle. L'échelle est reliée à la période, donc à la fréquence.

Un code couleur permet de donner la valeur de la transformée en ondelettes pour chaque point du graphique (Figure 8).

Les processus périodiques forment des lignes horizontales, alors que les impulsions forment des lignes verticales. L'effet d'un pompage ponctuel, par exemple, peut être observé en une ligne verticale, localisée dans le temps. L'échelle d'un phénomène quasi-périodique (hautes-eaux par exemple) donne une indication sur la période à laquelle survient ce type d'évènement. Ainsi, sur la Figure 8, on peut observer des tâches rouges correspondant environ à la composante 350 jours, que l'on peut relier aux automnes pluvieux. De même, les tâches plus importantes rouges, correspondant aux années 94 à 97 sont interprétées comme étant des années très pluvieuses, au contraire des années 87 à 93 où le bleu est dominant. Cette observation peut être mise en relation

avec la figure 35 (Indices centrés réduits des séries chronologiques de pluie et de débit de 1988 à 2004) du chapitre III concernant le système karstique du Lez, et qui délivre la même information concernant les années sèches et humides. Par ailleurs, les zones verticales sombres, localisée durant l'été, signifient que le débit est constant. Elles correspondent aux périodes pour lesquelles le débit de la source du Lez provient uniquement du débit réservé.



Figure 8 : Spectre en ondelettes continues du signal de débit de la source du Lez sur la période 1987-1999 (communication personnelle A. Mangin).



L'utilisation des ondelettes discrètes et continues à différents pas de temps a permis à D. Labat *et al.* (2000) de dégager la structure temporelle de la réponse du bassin versant étudié à la pluie. L'analyse en ondelettes discrètes a permis aux auteurs de séparer le signal de débit en deux composantes : une composante rapide, correspondant probablement aux écoulements dans les conduits karstiques, et une composante lente probablement due à un transfert plus lent dans la matrice poreuse et les fissures.

D. Labat *et al.* (2002) ont utilisé l'analyse corrélatoire croisée, couplée à une transformée en ondelettes discrète sur des signaux pluie-débit d'un système karstique pyrénéen. Les auteurs ont calculé les corrélations croisées des transformées en ondelettes des chroniques de pluie et de débit pour une même échelle. Ils en ont déduit des fonctions d'intercorrélation, échelle par échelle. La valeur du maximum de ces fonctions d'intercorrélation indique la causalité de la relation pluie-débit pour chaque échelle. Les auteurs notent que les allures des fonctions d'intercorrélation sont dépendantes de l'importance de la karstification du système étudié.

2.3. Modélisation pluie-débit conceptuelle

Dans le cas des aquifères karstiques au sein desquels les écoulements sont régis par la géométrie complexe et inconnue du karst, il est difficile de mettre en place un modèle fondé sur la physique

des processus mis en jeu lors de la transformation de la pluie en débit. Cette dernière est en effet complexe, dépendante d'une grande quantité de paramètres.

La mise en place d'un modèle global de simulation ou de prévision du débit se révèle, bien évidemment, utile pour la gestion des ressources d'un système karstique, ou encore pour la prévision de crue. Dans ces derniers cas, il est suffisant de mettre en place un modèle d'inspiration non physique : conceptuel ou statistique, efficace mais moins utile *a priori* pour la compréhension du système.

Cependant, l'étude d'un hydrosystème et plus particulièrement de sa réaction face aux perturbations engendrées par la pluie ou par un éventuel pompage, peut être enrichie par une modélisation visant à représenter avec plus de détails le fonctionnement du système. Plusieurs études proposent donc une démarche de modélisation non physique d'un système karstique, pour interpréter les valeurs des paramètres obtenus par calage, ou bien pour expliquer les éléments manquants au modèle et qui auraient permis d'obtenir de meilleurs résultats.

L'approche systémique offre donc une alternative intéressante à la modélisation physique puisqu'en représentant le fonctionnement global du système elle permet d'obtenir des connaissances physiques ou naturalistes sur le système étudié. C'est dans cette approche que se sont situés nos travaux de thèse.

2.3.1. Généralités sur les modèles conceptuels pour les hydrosystèmes karstiques

Conception

En général, un système est composé de plusieurs éléments qui réalisent une fonction. Le système communique avec l'extérieur grâce aux variables d'entrée et de sortie. Dans le cas d'un hydrosystème, on aura donc la pluviométrie et les mesures de débit comme variables d'entrée et de sortie, et un ensemble de « boîtes » assemblées qui réalisent la fonction de transformation de la pluie en débit. Selon les modèles, les « boîtes » prises en compte peuvent varier mais les principaux phénomènes représentés sont l'évapotranspiration, le passage dans un sol, l'infiltration lente, l'infiltration rapide, le passage dans l'épikarst, la zone noyée, les effets d'un pompage ou d'un apport extérieur (par une perte* par exemple). Le modèle peut fonctionner en continu (sur un ou plusieurs cycles ou années hydrologiques), ou au contraire de façon événementielle, ne prenant en compte que des épisodes de crue.

Chaque « boîte » comprend un ou plusieurs réservoirs qui se remplissent et se vident, représentant ainsi le stockage et la circulation de l'eau dans l'hydrosystème. Cela reste cependant une approche de type empirique : à la différence des modèles à base physique, les paramètres des modèles conceptuels ne peuvent pas être estimés, même partiellement, à partir de caractéristiques physiques du système. Contrairement aux modèles physiques, la phase de calage est donc un passage obligé dans la mise en œuvre d'un modèle conceptuel. Ainsi, des simulations de même qualité peuvent être issues de modèles possédants des paramètres très différents.

Les réservoirs peuvent être linéaires ou non-linéaires. Considérons l'exemple d'un réservoir linéaire pour lequel la variation du stock dans le réservoir (le volume ou la hauteur d'eau) est la différence entre ce qui entre et ce qui sort du réservoir :

$$\frac{ds}{dt} = u - Q \qquad \qquad \acute{Equation 14}$$

Où *u* est la variable d'entrée, c'est dire généralement le volume entrant de pluie efficace (la pluie dont l'eau évapotranspirée a été retirée), ou la sortie du réservoir précédent, et *Q* le débit en sortie du réservoir.

Soit T un paramètre correspondant au temps de résidence moyen de l'eau dans le réservoir. On peut écrire :

$$\frac{dS}{dQ} = T \qquad \qquad \acute{Equation 15}$$

Et l'équation 14 devient alors

$$T\frac{dQ}{dt} = u - Q \qquad \qquad \acute{Equation 16}$$

Si l'on considère u' une pluie efficace impulsionnelle, et que l'on suppose comme condition initiale que le débit vaut Q_0 à t_0 , la solution analytique de cette équation est :

$$Q(t) = Q_0 + \frac{u'(t_0)}{T} e^{\left[-\frac{t-t_0}{T}\right]}$$
 Équation 17

Cette réponse impulsionnelle correspond à la vidange exponentielle d'un réservoir, bien connue en hydrologie sous le nom de loi de Maillet.

Où les paramètres à caler sont : Q_o le débit initial et T le temps de résidence moyen dans le réservoir. Ce dernier est souvent remplacé par le coefficient de tarissement $\alpha = 1/T$.

Dans la théorie des systèmes, l'équation 16 est celle d'un système linéaire intégrateur du 1^{er} ordre de constante de temps T.

Le comportement non linéaire d'un réservoir implique l'existence de plusieurs coefficients de tarissement, fonction de la hauteur d'eau dans le réservoir. La détermination du seuil à partir duquel on passe d'un coefficient de tarissement à l'autre constitue alors un nouveau paramètre à ajuster.

Le modèle considère deux fonctions :

- La fonction de production qui consiste à transformer la pluie brute mesurée en pluie efficace, qui constitue l'entrée à proprement parler du système.
- La fonction de transfert (à ne pas confondre avec la fonction de transfert de l'analyse des systèmes linéaires) qui permet le passage de la pluie efficace en débit à l'exutoire du système.

Des lois de vidanges, permettant de lier la hauteur d'eau dans le réservoir au débit sortant du même réservoir, sont définies. Historiquement, pour les premiers modèles à réservoirs, les lois de vidanges étaient le plus souvent linéaires, de type loi de Maillet. Aujourd'hui les modèles, qu'ils se veulent simplifiés ou, au contraire, complexes et plus proches de la réalité, comportent tous des lois de vidanges non linéaires, comportant généralement un seuil.

Critères de qualité

Lorsqu'un modèle est utilisé pour simuler le fonctionnement hydrodynamique d'un aquifère, l'hydrogramme simulé est comparé à l'hydrogramme mesuré afin d'estimer les performances du

modèle. Plusieurs critères permettent de quantifier ces performances et de comparer entre eux plusieurs modèles.

Pour une meilleure évaluation, les critères sont souvent choisis en fonction de l'objectif de la modélisation. Par exemple pour une modélisation visant à estimer des crues, on privilégiera les critères portant sur les pics, ou du moins sur les plus fortes valeurs.

Dans ce travail deux types de critères ont été utilisés ; il s'agit du critère de Nash, très largement utilisé en hydrologie, et du critère de persistance qui a été spécifiquement développé pour évaluer les performances d'un modèle en prévision. Dans la suite on notera Q_m le débit mesuré, $\overline{Q_m}$ sa moyenne et Q le débit calculé par le modèle, k le temps discrétisé et n le nombre d'échantillons sur lequel le critère est calculé.

- Le critère de Nash (J. Nash et J. Sutcliffe, 1970)

C'est le critère le plus largement utilisé en hydrologie, pour la prévision comme pour la simulation, en continu ou en événementiel. Il n'est autre que le coefficient de détermination utilisé en statistique, et il s'exprime de la façon suivante :

$$R^{2} = 1 - \left(\frac{\sum_{k=1}^{n} (Q_{m}(k) - Q(k))^{2}}{\sum_{k=1}^{n} (Q_{m}(k) - \overline{Q_{m}})^{2}}\right)$$
 Équation 18

Ce critère revient à comparer le modèle à un « modèle moyen », c'est-à-dire renvoyant pour tous les instants discrets *k*, la moyenne du débit sur la période considérée. Si le critère de Nash est positif, cela signifie que le modèle utilisé est meilleur que le modèle qui ne calcule que la moyenne. Dans l'autre cas, si le critère de Nash est négatif, le modèle utilisé est moins bon que ce modèle « moyen », ce qui démontre l'inadéquation du modèle utilisé.

La valeur maximale, correspondant à une modélisation parfaite, est de 1. Appliqué à l'hydrologie, on considère que la modélisation est acceptable si le critère de Nash est supérieur à 0,6-0,7. Audelà de 0,9, le modèle est considéré comme bon à excellent.

Il faut noter que dans l'expression du critère, le numérateur correspond à l'erreur quadratique moyenne. Ainsi, minimiser l'erreur quadratique revient à maximiser le critère de Nash.

Ce critère prend en compte toute la durée de l'évènement ou du cycle hydrologique choisi comme ensemble d'évaluation, ou de test (indépendant des ensembles de calage ou d'apprentissage voir chapitre II). Ceci peut être gênant dans le cadre de la prévision de crue, contexte dans lequel la priorité n'est pas de simuler très correctement l'ensemble de la chronique mais au contraire d'avoir la meilleure prévision possible sur la montée et le pic de crue, même si cela doit se faire au détriment d'une simulation correcte de la décrue.

On doit noter *a contrario* que le critère de Nash n'est pas toujours satisfaisant selon les objectifs de la modélisation, en particulier pour la prévision ; pour cela le critère suivant, appelé critère de persistance, a été proposé.

- Critère de persistance

Le critère de persistance (P.K. Kitanidis & R.L. Bras, 1980) a été spécialement conçu pour évaluer les performances d'un modèle en prévision (entrée mesurée au jour *j* pour prévoir la sortie au jour *j*+*h*, avec *h* l'horizon de prévision). De la même façon que le critère de Nash compare la prévision du modèle utilisé à une prévision « calcul de la moyenne », le critère de persistance compare la

prévision effectuée avec la prévision dite « naïve », qui considère que le débit à l'horizon de prévision h ne varie pas, par rapport à la dernière mesure effectuée : $Q_{naïf}(k+h)=Q_m(k)$. Le critère de persistance se calcule de la façon suivante :

$$C_p = 1 - \frac{\sum_{k=1}^{n} [Q_m(k+h) - Q(k+h)]^2}{\sum_{k=1}^{n} [Q_m(k+h) - Q_m(k)]^2}$$
 Équation 19

Le critère de persistance est égal à 1 si la prévision est parfaite, et il est négatif si le « modèle naïf », qui au demeurant n'apporte aucune information, est plus performant que le modèle utilisé.

On comprend aisément que plus l'horizon de prévision est court, plus la prévision naïve est proche de la prévision observée. Il est donc plus difficile d'effectuer une meilleure prévision que la prévision naïve. A l'inverse, plus l'horizon de prévision est grand, moins la prévision naïve a de lien avec le débit observé et donc plus il est facile de définir un modèle délivrant une prévision meilleure que la prévision naïve.

Ce raisonnement simple, mais souvent négligé dans les articles présentant des résultats de prévision, est illustré dans la Table 8 de l'article « Complexity selection of a neural network model for karst flood forecasting : The case of the *Lez* Basin (southern France) » présenté au chapitre IV. Dans cet article, le calcul des critères de Nash obtenus par le « modèle naïf» est présenté. Pour un horizon de prévision de un jour, le critère de Nash est de 0,85 ce qui signifie que les prévisions ayant un critère de Nash inférieur à cette valeur n'apportent aucune valeur ajoutée par rapport à la prévision naïve. Ce même critère de Nash obtenu par le modèle « naïf » est de 0,53 pour un horizon de prévision de trois jours.

Résultats concernant la connaissance du système

Au-delà de la bonne simulation ou prévision d'un hydrogramme, certains modèles sont conçus dans le but de mieux comprendre le fonctionnement d'un hydrosystème.

Certains auteurs considèrent comme physiquement interprétables les paramètres des modèles conceptuels, par exemple la hauteur d'eau initiale dans un réservoir, le temps de transfert, le seuil de débordement, etc. Ceci est discuté notamment par R. Liden et J. Harlin (2000) et V. Andreassian *et al.* (2001) qui montrent que dans certains cas, la simulation de débit reste satisfaisante pour différents jeux de paramètres issus de plusieurs méthodes de calage différentes, ce qui ne permet pas d'interpréter les paramètres au sens physique. Ainsi, V. Andreassian *et al.* (2001) ont effectué plusieurs calages sur 3 modèles différents et en utilisant à chaque fois des données de pluies différentes. Les auteurs ont distingué deux comportements : l'un pour lequel les valeurs des paramètres convergent vers un jeu de valeurs identiques, et le second pour lequel ce jeu de valeurs change à chaque fois que l'on change d'entrée de pluie.

Pour éviter ces inconvénients, V. Cooper *et al.* (2007) ont présenté une méthode permettant de contraindre les paramètres d'un modèle conceptuel de façon à ce qu'ils ne puissent prendre que des valeurs physiquement plausibles. Les auteurs ont utilisé des débits fictifs pour tester leur modèle. Ils précisent que le modèle conceptuel choisi est supposé représenter correctement la réalité en termes de fonctionnement de l'hydrosystème, ce qui est une hypothèse forte dans le cas des systèmes karstiques qui sont les sujets de ce mémoire.

2.3.2. Modèles conceptuels appliqués aux karsts

Les modèles présentés dans ce paragraphe illustrent le propos du paragraphe précédent au moyen d'exemples d'utilisation de réservoirs pour représenter différentes fonctions du karst, sur des karsts de différentes tailles, soumis à différents climats, et comportant des jeux de données de différentes taille. Pour chaque modèle sont donnés l'agencement des « boîtes » représentant les fonctions, l'échantillonnage des signaux, l'échelle de l'aquifère modélisé, les périodes de calage et de validation ainsi que les performances du modèle.

Le modèle VENSIM

Le logiciel VENSIM® a été utilisé par A. Hreiche (2003) pour écrire un modèle hydrologique à réservoir appelé MEDOR. Dans notre étude nous considèrerons un autre modèle à réservoir, également développé sous VENSIM®, par P. Fleury *et al.* (2007 et 2008) au BRGM et qui sera par la suite appelé modèle VENSIM. Ce modèle à réservoirs vise à simuler les débits de sources karstiques. Le logiciel VENSIM permet de composer un modèle en fonction du bassin étudié. Par exemple, la simulation du débit à la Fontaine de Vaucluse a été réalisée en utilisant un modèle à trois réservoirs : un réservoir sol, non linéaire, qui produit la pluie efficace, et deux réservoirs linéaires pour la fonction de production. Les deux derniers réservoirs sont en parallèle, l'un a une vidange lente et l'autre une vidange rapide. Le modèle comporte six paramètres dont trois obtenus par l'analyse de l'hydrogramme à la source.

Le modèle VENSIM a été mis en œuvre sur plusieurs sources karstiques soumises à des conditions climatiques différentes, avec des bassins versants de superficies variées et différentes importances de karstification (quatre sources sur le Larzac, Fontaine de Vaucluse, Ardennes,...); les aquifères diffèrent également par la possibilité d'intrusions marines, l'éventuelle alimentation par des pertes... Sur l'ensemble servant à la validation, le coefficient de Nash est toujours supérieur à 0,70, atteignant 0,92 pour la simulation du débit à la Fontaine de Vaucluse (P. Fleury *et al.,* 2007).

Un modèle similaire a été appliqué au système du Lez pour simuler, soit le débit, soit la piézométrie dans le drain principal (voir chapitre III), avec le même jeu de paramètres. Sur ce modèle spécialement défini pour le Lez, le réservoir sol a été retiré au profit d'un réservoir zone saturée, dans lequel est prélevé le débit pompé (exploitation de la source pour l'eau potable depuis 1982, voir chapitre III). Les performances du modèle en termes de coefficient de Nash sont de 0,80 pour le débit et 0,70 pour la piézométrie (P. Fleury *et al.*, 2008). Une présentation plus approfondie de ces derniers résultats sera proposée au chapitre IV de ce mémoire où il sera question de la comparaison entre le modèle VENSIM et le modèle à réseaux de neurones pour effectuer l'estimation du débit ou de la piézométrie de la source du Lez.

Modèle du Coulazou

Le modèle proposé par V. Bailly-Comte (2008) a été construit pour simuler les débits de crue d'une rivière dont le bassin d'alimentation comporte une partie karstique et une partie nonkarstique. L'état des connaissances sur le bassin permet à l'auteur d'envisager une modélisation à base physique et spatialisée pour les écoulements de surface. En revanche les écoulements souterrains, opérant dans un karst, sont traités par une modélisation conceptuelle à réservoir. La modélisation est effectuée dans le but d'interpréter physiquement les paramètres calés du modèle, au nombre de 4, en particulier les paramètres régissant les échanges surface-souterrain qui sont comparés à l'humidité des sols et à la piézométrie mesurée sur le bassin.

Le réservoir représentant le karst est alimenté par les pertes et infiltrations qui opèrent au niveau d'un sous-bassin amont, deux paramètres règlent respectivement le pourcentage de l'eau du bassin amont qui s'infiltre et le pourcentage d'eau qui s'y perd. La sortie du réservoir est un débit, qui est ajouté au ruissellement de surface calculé sur les différents sous-bassins, pour parvenir au débit de sortie du modèle. La vidange du réservoir se fait de façon linéaire en fonction du volume d'eau présent dans le réservoir et d'un coefficient de tarissement α à caler. Un paramètre permet d'évacuer une partie de l'eau vers des exutoires sortant de l'hydrosystème considéré. L'objectif principal étant d'interpréter les paramètres, ces derniers sont ajustés pour chaque crue. Le coefficient de Nash varie de -0,28 à 0,95 selon l'évènement, et il est généralement proche de 0,8.

L'auteur remarque que le coefficient de tarissement du réservoir du modèle est linéairement corrélé ($r^2 = 0.95$) à la vidange observée (elle-même fonction de la piézométrie mesurée) dans la cavité karstique faisant office de source. Il précise cependant que, si cette relation donne du sens au paramètre, elle ne peut être utilisée pour le déterminer.

De la même façon, l'auteur note que le coefficient de tarissement α et le volume d'eau qui se perd sont inversement proportionnels à la piézométrie initiale mesurée en début d'évènement. Le coefficient de corrélation entre ces deux paramètres et la piézométrie est cependant assez faible : 0,76 pour le volume d'eau qui se perd et 0,79 pour α .

Modèle HYMKE (Hydrological Model for Karst Environment)

Le modèle HYMKE a été développé par A. Rimmer et Y. Salingar (2006) pour les besoins de modélisation des débits journaliers du Jourdain (Israël). Trois affluents sont pris en compte, provenant de terrains karstiques. Le bassin d'alimentation du Jourdain au niveau de la station qui enregistre les débits de sortie considérés est de 1700 km².

Le modèle comporte 13 paramètres répartis sur quatre modules : épikarst, zone d'infiltration, écoulements souterrains et écoulements de surface. Il prend donc en compte non seulement les écoulements souterrains dans le karst mais aussi les écoulements de surface qui s'opèrent sur les parties imperméables du bassin. Le module épikarst est constitué d'un réservoir non linéaire alors que les autres modules sont un assemblage de réservoirs linéaires. Ce modèle a la particularité de fournir des « sorties intermédiaires » correspondant aux débits issus de trois affluents, qui sont vérifiables grâce aux mesures disponibles.

La décomposition des hydrogrammes en débit de base et débit de surface par une méthode de traitement du signal, qui permet de séparer basses fréquences et hautes fréquences permet l'estimation de plusieurs paramètres du modèle. Les auteurs précisent cependant que cette méthode ne permet pas de séparer les écoulements de surfaces (plus rapides que les écoulements souterrains) des réactions rapides que peut délivrer le karst notamment en cas de fortes crues. Ces réactions souterraines brutales sont donc prises en compte comme de l'écoulement de surface par le modèle.

Après calage, le modèle est testé sur un ensemble indépendant de 20 ans, le coefficient de Nash est de 0,87 ce qui signifie que le modèle a une performance acceptable, mais pas excellente. Les auteurs constatent un manque de précision sur les évènements les plus forts, selon eux dû à la 44

non prise en compte de la fonte des neiges. Les « sorties intermédiaires » du modèle restent cohérentes avec les mesures et la séparation de l'hydrogramme en écoulement de base/de surface. Ce modèle a l'avantage d'être modulable en fonction des besoins puisque chaque module peut être testé et utilisé indépendamment des autres. En contrepartie, le nombre de paramètres est très élevé. Pour un modèle à réservoirs, ce modèle est très complexe et permet de représenter les différentes contributions, souterraines ou de surface, d'un vaste bassin versant. Ses performances ne sont pas excellentes et son calage nécessite de longues séries chronologiques. Il a été particulièrement développé pour le bassin du Jourdain mais peut être adapté à d'autres bassins comprenant plusieurs affluents.

Ce modèle est présenté car il partage avec notre étude l'hypothèse d'un modèle postulé comportant plusieurs bassins d'alimentation souterrains (voir chapitre V), et à ce titre est qualifié de « boîte grise » par ses auteurs. La différence entre les deux travaux est, outre le modèle, le fait que des mesures de débits aux exutoires intermédiaires de ce système peuvent être réalisées. Le modèle HYMKE, à l'exception de l'épikarst est cependant linéaire, ce qui limite ses capacités de modélisation des écoulements karstiques. On peut également souligner la difficulté de réaliser le calage « manuel » des nombreux paramètres afin que ces derniers conservent une vraisemblance physique.

Modèle dédié à l'estimation du bilan en eau

D. Jukic et V. Denic-Jukic (2009) proposent un modèle permettant d'estimer le bilan en eau d'un aquifère au moyen de simulation des débits journaliers d'une source karstique dont le bassin d'alimentation est estimé à 396 km² : la source Jadro en Croatie. Les auteurs disposent pour cela de mesures de pluie et de débits sur 10 cycles hydrologiques. Le modèle comporte 14 paramètres et se décompose en deux parties : une partie sol et épikarst et une partie écoulements souterrains comportant trois réservoirs. L'un d'eux, qui représente les fractures et fissures en zone non-saturée, est non linéaire alors que les deux autres sont linéaires et représentent d'une part les joints et micro-fissures (circulation lente) et d'autre part les drains verticaux. L'objectif de ce modèle est de proposer un bilan des écoulements souterrains et d'ainsi évaluer la capacité de stockage de l'aquifère. Les paramètres sont initialisés avec des valeurs physiquement plausibles (qui impliquent notamment que le bilan hydrologique soit équilibré) et optimisés en minimisant la fonction d'erreur entre le débit simulé et le débit observé. L'algorithme de Levenberg Marquardt (Annexe B) est utilisé pour effectuer cette optimisation. Le coefficient de Nash obtenu est de o,88 pour le modèle entier (sol, épikarst, souterrain) et de o,98 pour la partie concernant les écoulements souterrains.

Comme pour le modèle précédent on doit, ici aussi, souligner la complexité du calage de ce modèle qui, même s'il est automatisé par une descente de gradient, est appliqué dans une séquence particulière afin de contraindre les paramètres à conserver des valeurs physiquement plausibles.

2.3.3. Conclusion sur les modèles conceptuels

Nous avons vu qu'il existe une grande variété de modèles pluie-débit à réservoirs, appliqués à des questionnements parfois très différents. La simplification à l'extrême des processus physiques autorise même souvent l'utilisation d'un même modèle pour différents types d'aquifères. Mais il

faut garder à l'esprit, comme le souligne B. Marsaud (1997) que les bons résultats obtenus par ce type de modèle ne sont pas forcément des indicateurs de la bonne représentativité des modèles par rapport à la réalité. C'est pourquoi il faut être particulièrement vigilant sur l'interprétation à donner aux paramètres calés, qui ne sont généralement pas des quantités mesurables sur le terrain.

Globalement les calages sont satisfaisants, mais pas toujours la validation. Il existe une grande confusion pour ce qui est des performances de ces modèles en termes de généralisation. En effet, les coefficients de Nash sont souvent donnés pour la période de calage seule ou pour la période entière comprenant le calage et la validation. Or l'erreur de généralisation ne peut être estimée que sur la période de validation, et lorsque celle-ci ne comprend que des évènements ou des années jamais rencontrés auparavant. Également, il est assez rare que les performances en prévision soient quantifiées à l'aide d'un critère spécifique comme celui de persistance, or nous avons vu que la seule valeur du critère de Nash ne permet pas d'évaluer réellement l'apport d'information du modèle.

Les études récentes concernant l'application de modèles conceptuels aux systèmes karstiques visent à approcher les caractéristiques physiques des systèmes karstiques étudiés, que ce soit par l'interprétation des paramètres calés dans des conditions précises, ou par la simulation de flux d'eau, flux « intermédiaires » entre la pluie mesurée et le débit à l'exutoire. Parallèlement, il s'agit d'améliorer les modèles conceptuels en y intégrant les connaissances récemment acquises comme dans le cas du modèle de V. Bailly-Comte (2008) ou en ajoutant de la complexité nécessaire, par exemple en prenant en compte la présence d'exutoires non mesurés. Dès que les modèles cherchent à se rapprocher de la physique des processus, on peut noter que le nombre de leurs paramètres augmente rapidement et que la procédure de calage devient extrêmement complexe. L'application de méthodes d'optimisation du calage des modèles, selon un critère choisi, reste encore peu répandue.

3. Conclusion du chapitre I

Ce chapitre a présenté les aquifères karstiques, en mettant l'accent sur les difficultés rencontrées pour leur description et leur étude. Du fait de leur mode de formation particulier, par dissolution de la roche carbonatée, qui conduit à une forte hétérogénéité de structure, le réseau de fractures et de fissures élargies par la dissolution s'auto-organise de façon à drainer l'eau vers le ou les exutoires. Ainsi, chaque système karstique est unique et susceptible d'évoluer dans le temps, en fonction de la conjonction des conditions favorables à la karstification. Un schéma fonctionnel global a cependant pu être proposé, prenant en compte l'organisation verticale du karst. Chacun des deux ou trois niveaux proposés (épikarst, zone non saturée, zone noyée) comporte une ou plusieurs « boîtes » représentant un processus particulier tel que le stockage, l'infiltration rapide, l'infiltration lente, Cette représentation permet de considérer le karst comme un système, réalisant une succession de fonctions.

S'appuyant sur le concept de système, l'approche systémique propose plusieurs méthodes d'étude du karst qui peuvent être appliqués à tout système karstique pour lequel on dispose de mesures de pluie et de débit. Les analyses corrélatoires et spectrales simples et croisées, méthodes empruntées au domaine du traitement du signal, permettent de quantifier dans le

temps l'importance de la relation entre la pluie, de un ou de plusieurs pluviomètres, au débit à l'exutoire du système, et ainsi d'évaluer l'inertie du système qui peut être reliée à la présence de stockage de l'eau. L'analyse des débits classés permet de détecter la présence d'autres exutoires ou d'apports extérieurs au système. La décomposition en ondelettes est complémentaire de l'analyse spectrale et permet d'estimer l'importance de la karstification du système. Toutes ces méthodes ne nécessitent que des données d'entrée (pluie) et de sortie (débit) du système ce qui les rend attractives et applicables dans de nombreux cas. Cependant toute information complémentaire sur le système permet d'enrichir considérablement l'interprétation des résultats obtenus.

Dans le domaine de l'étude des karsts, les avancées les plus récentes concernent la modélisation, utilisée non seulement pour simuler et prévoir les débits de sources karstiques, mais aussi pour améliorer la connaissance sur le système karstique étudié. Les modèles conceptuels, qui ont été présentés dans ce chapitre, s'appuient sur l'approche systémique pour représenter le karst sous forme d'un assemblage de boîtes réalisant chacune une fonction particulière, à l'aide de un ou plusieurs réservoirs.

En fonction de la structure du modèle, et de leur degré de conceptualisation, les auteurs tentent d'interpréter les valeurs des paramètres obtenus lors de la phase de calage. Certains peuvent être comparés avec des données mesurables sur le terrain. Cependant, cette comparaison reste difficile et l'interprétation des paramètres est encore discutée, d'autant que peu de modèles fournissent une simulation des débits suffisamment bonne pour permettre de valider les hypothèses sous-jacentes sans contestation.

Néanmoins, compte-tenu des enjeux liés à la meilleure connaissance hydrodynamique des aquifères karstiques, nous allons présenter dans le chapitre suivant une méthode de modélisation inscrite dans la ligne des méthodes systémiques, mais qui ne nécessite pas de poser des hypothèses de fonctionnement *a priori*. Il s'agit des réseaux de neurones, qui, par leur capacité à identifier les relations non linéaires, paraissent particulièrement adaptés à la modélisation de systèmes aussi complexes que les aquifères karstiques.

Chapitre II : L'apprentissage statistique pour l'identification des hydrosystèmes

Après avoir exposé les fondements et l'intérêt de l'approche systémique pour l'étude du karst au chapitre I, nous présentons maintenant les développements effectués en ce sens par l'application de l'apprentissage statistique à la modélisation hydrologique. Plus spécifiquement, nous nous focaliserons sur les travaux concernant les réseaux de neurones formels, ces derniers faisant l'objet de ce travail de thèse.

La terminologie utilisée dans le domaine des réseaux de neurones formels rappelle que ces fonctions ont été inspirées par ce que l'on connaît du fonctionnement d'un cerveau biologique (*neurones, coefficients synaptiques, apprentissage*). Toutefois cette approche appartient clairement au domaine de l'apprentissage statistique et la comparaison avec le fonctionnement biologique des neurones n'est évoquée que pour l'aspect historique de l'initiation des travaux sur les modèles neuronaux. Les réseaux de neurones formels, qui seront appelés « réseaux de neurones » dans toute la suite de ce manuscrit, constituent une famille de modèles non linéaires, mis en œuvre dans cette étude pour la tâche d'identification de fonction. Les réseaux de neurones apparaissent alors comme des modèles de type « boîte noire » permettant la modélisation d'un processus, ici la transformation de la pluie en débit, sans que cette fonction soit explicitée.

Les fondamentaux concernant les réseaux de neurones sont exposés dans un premier paragraphe, suivi d'une section concernant l'apprentissage du réseau.

En considérant l'apprentissage comme le calcul d'une régression non linéaire, apparaît la problématique de la généralisation, c'est à dire la capacité du modèle à généraliser ce qu'il a appris à des exemples jamais rencontrés. Le dilemme biais-variance, principe au cœur de l'apprentissage statistique nous indique de plus, que pour maximiser les performances de généralisation, il est utile de faire appel à des méthodes de régularisation, ou de diminution de la variance sur l'ensemble de généralisation. Cette problématique tiendra une grande place dans le présent chapitre ; elle est l'objet de l'article à paraître dans la revue *Environmental Earth Sciences* que nous y reproduisons.

Enfin le troisième paragraphe établit un état de l'art de la modélisation hydrologique par réseaux de neurones, en particulier concernant le problème des hydrosystèmes karstiques, et la mise en œuvre de modèles permettant d'inclure des informations *a priori* dans le modèle et/ou d'extraire du modèle des informations physiquement non mesurées.

1. Présentation des réseaux de neurones

1.1. Neurone formel

Un neurone est un opérateur mathématique qui transforme une ou plusieurs variables d'entrée (vecteur x) en une ou plusieurs valeurs de sortie (on considèrera par la suite une valeur de sortie : le scalaire y). Le neurone réalise une fonction algébrique, non linéaire, de ses variables entrées :

$$y = f(x_0, \dots, x_n; w_0, \dots, w_n)$$

Avec $\{x_i, 0 \le j \le n\}$ les variables et $\{w_i, 0 \le j \le n\}$ les paramètres

Les neurones fonctionnent de la façon suivante :

Tout d'abord, le neurone calcule son *potentiel* : la somme pondérée de ses entrées. Les paramètres, coefficients de pondération, ou coefficients synaptiques, sont calculés durant la phase d'apprentissage.

Le potentiel du neurone subit ensuite une transformation, opérée par une fonction *f*, appelée *fonction d'évaluation* ou *fonction d'activation du neurone*. Plusieurs fonctions d'activation existent : La fonction d'activation de Heaviside est un seuil binaire, par exemple à valeurs o ou 1, selon que le potentiel du neurone est positif ou négatif. La fonction d'activation sigmoïde est en général une tangente hyperbolique, présentant l'avantage d'être continue et dérivable. Enfin la fonction d'activation peut être la fonction identité ; dans ce cas le neurone est linéaire.



Figure 9 : Représentation schématique d'un neurone formel

On a ainsi $y = f(\sum_{j=0}^{n} (w_j x_j))$ où f est la fonction d'activation, et comme précédemment $\{x_j\}$ sont des variables d'entrée et $\{w_i\}$ sont des paramètres.

Dans le cas des neurones à fonction d'activation sigmoïde, un traitement préalable des variables d'entrée est indispensable, et ce de façon à ramener toutes les variables à des ordres de grandeur similaires. Ainsi les variables ayant des valeurs faibles pourront être prises en compte au même titre que les variables ayant des valeurs fortes. De plus, le traitement des données permet d'éviter d'avoir de fortes valeurs, pouvant entraîner la saturation des sigmoïdes. Les données doivent donc être normalisées de façon à ne pas atteindre les minimum et maximum de la fonction d'activation. Le traitement généralement utilisé est de centrer et de réduire par l'écart type les valeurs des variables ; néanmoins, dans le cas de variables hydrologiques, M. S. Toukourou (2007) a montré sur des bassins à crues rapides qu'il était plus efficace d'appliquer simplement une homothétie pour rendre ces variables inférieures à 1. Ce type de traitement appliqué au bassin karstique qui fait l'objet de notre étude a également donné des résultats satisfaisants. Dans notre étude, les fonctions d'activation atteignent leur maximum en 1 et sont minimales en -1 ; néanmoins les données sont réduites de façon à ce que le maximum soit 0,9.

1.2. Réseaux de neurones et architectures

Les réseaux de neurones sont un arrangement de neurones tels que décrits au paragraphe précédent selon une architecture particulière. Au sein d'un réseau, on pourra distinguer les *neurones cachés* des *neurones de sortie*. La sortie d'un neurone caché n'est pas une sortie du réseau et l'on ne dispose pas de valeurs mesurées de sa sortie. A l'inverse la sortie d'un neurone de sortie correspond à une sortie du réseau et, dans le cadre supervisé qui est celui de notre

travail, on dispose de valeurs mesurées de cette sortie. Parmi les différents réseaux de neurones existants, on peut distinguer les réseaux de neurones statiques et les réseaux dynamiques.

1.2.1. Les réseaux de neurones statiques

Dans un réseau statique, la sortie ne dépend que des entrées présentes à l'instant considéré et pas de l'état du réseau. La sortie du réseau de neurones est donc une fonction de *n* variables pour laquelle le temps n'a pas de rôle fonctionnel. Lorsque les variables d'entrées sont des signaux échantillonnés (chroniques de mesures à un pas de temps fixe par exemple) le réseau de neurones est un filtre numérique non linéaire et non récurrent (filtre transverse):

$$y(k) = \varphi_{RN}[\mathbf{x}(k), \dots, \mathbf{x}(k-n), \mathbf{w}]$$

Avec y(k) la sortie du filtre à l'instant discret k, $\mathbf{x}(k)$ le vecteur du biais et des n variables à l'instant k, \mathbf{w} le vecteur des paramètres, et φ_{RN} la transformation non linéaire opérée par le filtre.

La figure suivante présente un réseau statique de neurones. L'arrangement des neurones fait qu'il n'y a pas de cycle, ce type de réseau est donc un *réseau non-bouclé*.



Figure 10 : Exemple de réseau de neurones non-bouclé. *f* est la fonction d'activation des neurones cachés, et s est le neurone de sortie dont la fonction d'activation est généralement la fonction identité.

1.2.2. Les réseaux de neurones dynamiques

Comme pour les réseaux de neurones statiques, la sortie du réseau est une fonction de *n* variables externes, dites variables *exogènes*; elle est également fonction d'une ou plusieurs valeurs passées des sorties du même réseau de neurones qui sont appelées *variables d'état*. Ainsi, le temps joue un rôle fonctionnel puisque la sortie du réseau dépend d'une ou de plusieurs de ses sorties passées. Ainsi, même si les variables exogènes sont constantes, la ou les sorties pourront varier au cours du temps. On a donc bien un système dynamique.

La figure suivante illustre un réseau dynamique. Le neurone de sortie est relié, avec un retard -1, à l'entrée du réseau. Le réseau est donc *bouclé*.



f est la fonction d'activation des neurones cachés, et s est le neurone de sortie dont la fonction d'activation est généralement la fonction identité.

1.2.3. Apprentissage des réseaux dynamiques

Deux modes d'apprentissage peuvent être distingués pour les réseaux de neurones dynamiques : l'apprentissage *dirigé* et l'apprentissage *non-dirigé*, en fonction des valeurs utilisées au cours de l'apprentissage pour les variables d'état. Si les valeurs utilisées sont les valeurs observées, le mode d'apprentissage est dirigé par le processus, à l'inverse si ces valeurs sont estimées par le réseau lui-même, le mode d'apprentissage est non-dirigé.

O. Nerrand *et al.* (1993) ont montré comment mettre en place un mode d'apprentissage optimal en tenant compte des connaissances que l'on a du bruit et des perturbations opérant sur le modèle postulé, modèle hypothétique représentant le processus physique que l'on cherche à reproduire.

Soit le modèle postulé représenté en Figure 12 et qui réalise la fonction :

$$y(k + 1) = \varphi(y(k), ..., y(k - r + 1), u(k), ..., u(k - w + 1))$$
 Équation 20

où y(k+1) est la sortie future qui dépend des sorties estimées précédentes et de $\mathbf{u}(k)$ le vecteur des variables exogènes. r et w sont des entiers positifs. φ est une fonction.



Figure 12 : Modèle postulé récurrent.

Deux hypothèses peuvent être alors formulées : soit les perturbations (bruit de mesure par exemple) affectent le modèle postulé sur sa sortie (Équation 21), soit elles affectent son état (Équation 22) comme représenté en Figure 13. Ces deux possibilités sont représentées sur la Figure 12.

$$y^{p}(k+1) = \varphi(y^{s}(k), \dots, y^{s}(k-r+1), u(k), \dots, u(k-w+1)) + b(k+1) \quad \acute{Equation 21}$$

$$y^{p}(k+1) = \varphi(y^{p}(k), \dots, y^{p}(k-r+1), u(k), \dots, u(k-w+1)) + b(k+1) \quad \acute{Equation 22}$$

où $y^{p}(k+1)$ est la grandeur <u>observée du processus</u>, $y^{s}(k+1)$ est la <u>sortie du modèle postulé</u>, b(k+1) est un bruit de mesure qui agit sur la sortie à l'instant k+1. $\mathbf{u}(k)$ le vecteur des variables exogènes, r et w sont des entiers positifs, φ est une fonction.



a. Modèle postulé à hypothèse bruit de sortie







b. Modèle neuronal associé à hypothèse bruit de sortie



c. Modèle postulé à hypothèse bruit d'état d. Modèle neuronal associé à hypothèse bruit de sortie Figure 13 : Modèles postulés et modèle neuronal associé pour les deux hypothèses : bruit de sortie et bruit d'état.

Dans le premier cas, le modèle neuronal correspondant est un modèle récurrent tel que présenté au paragraphe précédent dont la sortie peut s'écrire :

$$y^{p}(k+1) = g_{rn}(y(k), ..., y(k-r+1), u(k), ..., u(k-w+1), w)$$
 Équation 23

avec g_{tn} la fonction réalisée par modèle neuronal et w le vecteur des paramètres.

Ce modèle peut donc effectuer des prévisions sans limitation quant à l'horizon de prévision, tant que l'on dispose des prévisions de ses variables exogènes.

Dans le second cas, le bruit affecte l'état du système, il est donc plus adéquat d'utiliser en entrée les variables <u>observées</u> du processus. Le modèle neuronal devra donc s'écrire :

$$y^{p}(k+1) = g_{rn}(y^{p}(k), ..., y^{p}(k-r+1), u(k), ..., u(k-w+1), w)$$
 Équation 24

Ce modèle est représenté en Figure 13. Il s'agit cette fois d'un modèle non récurrent puisque ses entrées sont les variables exogènes et la sorties observées du processus. Ce modèle correspond au mode d'apprentissage dirigé.

Ces deux types de modèles (et les apprentissages correspondants) ont été mis en œuvre dans cette étude; le modèle dirigé est utilisé pour la prévision des crues et la modélisation par boîte transparente (chapitres III et V), tandis que le modèle non-dirigé a été étudié pour la comparaison avec le modèle à réservoir VENSIM (Chapitre IV).

1.3. Le perceptron multicouche et ses propriétés

Le perceptron multicouche est un réseau à l'architecture particulière : toutes les entrées sont connectées à tous les neurones d'une première couche de *neurones cachés*. Tous les neurones d'une couche sont connectés à tous les neurones de la couche suivante. Les neurones cachés sont non-linéaires alors que les neurones de sortie sont linéaires ou non linéaires. Ce type de réseau possède des propriétés intéressantes qui sont énoncées et explicitées ci-après. La figure suivante illustre le perceptron multicouche dans le cas particulier d'une seule sortie. Il faut noter la présence d'une entrée constante appelé *biais* et qui effectue un décalage affine : le biais permet un décalage horizontal des sigmoïdes de la couche cachée et un décalage vertical de la sortie. Ainsi la sortie du réseau n'est pas obligatoirement nulle lorsque les entrées sont toutes nulles.



Figure 14 : Perceptron multicouche à une couche de neurones cachés.

La sortie y du réseau est calculée de la façon suivante :

avec:

$$y = w_{s,0}x_0 + \sum_{i=1}^{N_c} [w_{s,i}f(\sum_{i=0}^n w_{j,i}x_i)]$$

Équation 25

f(.) la fonction d'activation sigmoïde des neurones cachés,

w_{s,o} le paramètres reliant l'entrée constante au neurone de sortie,

w_{s,i} le paramètre reliant le neurone de la couche cachée d'indice j au neurone de sortie,

 $w_{j,i}$ le paramètre reliant la variable d'entrée x_i (*i*=1, *n*) au neurone de la couche cachée d'indice *j*, (*j*=1, *N*_c).

1.3.1. Approximation universelle

La propriété d'approximation universelle énonce que toute fonction bornée suffisamment régulière peut être approchée avec une précision donnée, arbitraire, par un réseau de neurones non bouclé, possédant une couche de neurones cachés ayant tous les mêmes fonctions d'activation bornée, et un neurone de sortie linéaire (G. Cybenko, 1989; K. Funahashi, 1989). Il convient de noter qu'il s'agit d'une propriété d'existence, et qui ne renseigne donc pas sur le moyen *ad hoc* de déterminer les paramètres. C'est néanmoins cette propriété qui fonde notre choix d'utiliser le perceptron multicouche pour réaliser la fonction d'identification dans notre travail.

1.3.2. Parcimonie

Selon A.R. Barron (1993), un approximateur dont la sortie dépend non linéairement de ses paramètres est plus parcimonieux qu'un approximateur dont la sortie dépend linéairement de ses paramètres. L'équation permettant de calculer la sortie du réseau de neurones (Equation 25)

montre que dans le cas du perceptron multicouche, la sortie dépend non-linéairement des paramètres du modèle. De plus, A.R. Barron (1993) montre également que pour obtenir une précision donnée, le nombre de paramètres du modèle croît exponentiellement avec le nombre de variables d'entrées si ce modèle est linéaire par rapport à ses paramètres. Alors que dans le cas où le modèle est non linéaire par rapport à ses paramètres, le nombre de paramètres croît linéairement avec le nombre de variables d'entrée.

La parcimonie du perceptron multicouche est donc d'autant plus importante en proportion que le nombre de variables d'entrée du modèle est grand.

2. Apprentissage et sélection du modèle

La phase d'apprentissage consiste à estimer les paramètres **w** du modèle par réseaux de neurones afin que sa sortie se rapproche d'une *sortie désirée*, correspondant dans notre travail aux mesures journalières de débit. Un ensemble de couples mesurés entrées-sortie est utilisé à cette fin. Cet ensemble étant fini, la fonction reliant les entrées à la sortie désirée ne peut être déterminée de façon univoque. L'objectif de l'apprentissage est donc de trouver la solution la plus parcimonieuse et qui se rapproche au mieux de la fonction entrée-sortie désirée.

Par ailleurs, les mesures, et donc les valeurs observées des sorties comme des entrées étant entachées d'erreur, on comprend bien que l'objectif n'est pas nécessairement de faire passer la fonction recherchée par tous les points d'apprentissage. De plus ceci conduirait au phénomène de surajustement que nous développerons dans la suite de ce chapitre

Cette partie est consacrée à l'explication du principe de l'apprentissage, du phénomène de surajustement et des méthodes qui permettent d'éviter ce surajustement. Ce dernier aspect, en relation avec la sélection du modèle, a fait l'objet d'une publication (L. Kong A Siou et al. 2011b) qui est incluse en deuxième partie de ce chapitre (2.2. Problème du surajustement).

2.1. Règles d'apprentissage

Disposant d'une base de données d'entrée-sortie, il est nécessaire dans un premier temps, de constituer un *ensemble d'apprentissage* composé de N couples d'entrée-sortie, c'est-à-dire de N mesures $\{y^k\}$ (k = 1,..., N) de la grandeur à modéliser (ici le débit), et des valeurs correspondantes des *n* variables (ici la pluviométrie) $\{x^k\} = \{[x_1^k,...,x_n^k]\}$.

L'ensemble d'apprentissage ne constitue pas la totalité de la base de données car d'autres ensembles doivent être mis de côté afin d'effectuer la validation du modèle.

2.1.1. Fonction de coût

L'apprentissage consiste à minimiser une fonction de coût, représentative des différences entre les valeurs mesurées de l'ensemble d'apprentissage et les valeurs calculées par le modèle. La fonction la plus couramment utilisée est la fonction des moindres carrés :

$$J(\boldsymbol{w}) = \sum_{k=1}^{N} \left[y^k - y(\boldsymbol{x}^k, \boldsymbol{w}) \right]^2$$
 Équation 26

avec $y(\mathbf{x}^k, \mathbf{w})$ la sortie du modèle pour les variables \mathbf{x}^k .

2.1.2. Optimisation

Comme le modèle n'est pas linéaire par rapport à ses paramètres, la fonction de coût citée plus haut n'est pas quadratique en ses paramètres et il n'est donc pas possible d'utiliser la méthode des moindres carrés pour minimiser cette fonction. L'apprentissage se fait donc avec des méthodes itératives d'optimisation qui utilisent le gradient de la fonction de coût. À chacun de ces algorithmes d'optimisation nous pourrons par la suite associer une « règles d'apprentissage », correspondant à un algorithme de modification des paramètres du réseau. À chaque itération, le gradient de la fonction de coût est calculé, puis les paramètres sont modifiés de façon à minimiser la fonction de coût.

La procédure suivie lors de l'apprentissage est alors la suivante :

- 1. Initialisation des paramètres \mathbf{w} , (w_j , j = 1, N).
- 2. Calcul du potentiel et de la sortie des neurones depuis la couche d'entrée vers le neurone de sortie.
- 3. Calcul du gradient de la fonction d'erreur $\nabla J(w)$.
- 4. Calcul de l'incrément à appliquer aux coefficients à partir du gradient de l'erreur.
- 5. Reprise de la procédure à l'étape 2 jusqu'au minimum de la fonction de coût.

Le calcul de gradient se fait en utilisant l'algorithme de rétropropagation (D.E. Rumelhart et al. 1986). À partir de ce dernier, plusieurs méthodes existent pour effectuer l'incrément à appliquer aux paramètres. On peut distinguer les méthodes du premier ordre qui utilisent le gradient simple de celles du second ordre qui utilisent les dérivées secondes ou leur approximation par un produit de dérivées premières. Les méthodes du premier ordre modifient les paramètres proportionnellement au gradient de la fonction de coût. C'est-à-dire qu'un coefficient μ , le pas du gradient, fixe ou variable, est multiplié à la valeur du gradient pour calculer l'incrément δw à appliquer aux paramètres :

$$\partial \boldsymbol{w} = -\mu . \nabla J(\boldsymbol{w})$$

Les méthodes du second ordre font intervenir la matrice hessienne, matrice des dérivées secondes de la fonction de coût par rapport aux paramètres. Ces méthodes sont reconnues comme étant les plus rapides à converger, c'est pourquoi c'est ce type de méthode qui a été utilisé dans ce travail. Le paragraphe suivant donne les grandes lignes des méthodes de gradient de second ordre.

Équation 27

2.1.3. Méthodes de second ordre

Comme précédemment, on considère la fonction de coût $J(\mathbf{w})$ à minimiser. En reprenant le raisonnement présenté dans Press *et al.* (1992) supposons que le réseau se trouve au point γ , proche du minimum de la fonction de coût que l'on souhaite atteindre, noté Ω .

En faisant l'hypothèse que, autour du point Ω , la fonction de coût $J(\mathbf{w})$ est quadratique, on peut la décomposer en séries de Taylor jusqu'au deuxième ordre, en négligeant les termes d'ordre supérieur. On effectue alors un incrément $\delta \mathbf{w}$ qui amène le réseau sur le minimum Ω :

$$J(\gamma + \delta w) = J(\gamma) + \nabla J(w) \cdot \delta w + \frac{1}{2} \delta w^{t} \cdot H(w) \cdot \delta w \qquad \acute{Equation 28}$$

Équation 30

où t désigne l'opérateur transposé et H correspond à la matrice hessienne. On rappelle que γ est le point où se trouve le réseau, supposé proche du minimum.

Au minimum de la fonction de coût, les dérivées sont nulles, donc si l'on considère δw l'incrément qui permet d'atteindre ce minimum, on peut écrire :

$$\frac{\delta J(\gamma + \delta w)}{\delta w} = 0 = \nabla J(w) + H(w). \,\delta w \qquad \qquad \acute{Equation 29}$$

ou encore :

$$\delta \boldsymbol{w} = -H^{-1}(\boldsymbol{w})\nabla J(\boldsymbol{w})$$

Ainsi, en pratique, lorsque la fonction $J(\mathbf{w})$ n'est pas quadratique, si l'initialisation du réseau, ou une première convergence avec une règle du premier ordre, permet d'atteindre le point γ proche du, ou d'un, minimum Ω de la fonction de coût, l'application de la dernière relation permet de converger vers ce minimum.

Plusieurs règles d'apprentissage se fondent sur ce raisonnement. Parmi elles, la méthode de Levenberg-Marquardt adaptée aux réseaux de neurones par M.T. Hagan et M.B. Menhaj (1994) permet d'approximer la matrice hessienne à partir des dérivées premières, calculées par la rétropropagation, évitant ainsi de calculer les dérivées secondes. Cette méthode est largement reconnue comme la méthode la plus efficace actuellement. Mais elle ne peut être utilisée pour des réseaux de grande dimension qui génèrent une matrice hessienne de trop grande taille. La méthode peut fonctionner jusqu'à plusieurs milliers de coefficients. C'est cette méthode qui a été utilisée dans la suite de cette étude, dans la mesure où les réseaux considérés sont de petite taille. Le détail de la règle d'apprentissage inspirée de l'algorithme de Levenberg-Marquardt est présenté en Annexe B.

2.2. Problème du surajustement

Le risque de l'utilisation de l'apprentissage statistique pour identifier une fonction de régression est le surajustement. Dans ce cas l'ajustement se fait non seulement sur les données disponibles mais aussi sur le bruit contenu dans ces données. Ce dernier ajustement n'est pas souhaitable car le modèle est alors incapable de généraliser à des données extérieures à l'ensemble d'apprentissage.

Le problème du surajustement est à relier avec la complexité du modèle : un modèle trop complexe sera trop « souple » et sera donc capable d'apprendre le bruit contenu dans les données d'apprentissage. A l'inverse, un modèle trop peu complexe ne sera pas assez souple pour s'ajuster correctement aux données d'apprentissage. Ce problème est connu sous le nom de *dilemme biais-variance* et constitue un enjeu majeur dans le domaine de l'apprentissage statistique.

Sur ce constat, une attention particulière a été portée à cette problématique dans cette étude pour, d'une part, éviter le surajustement durant l'apprentissage et d'autre part, sélectionner le modèle présentant les meilleures propriétés lors de la généralisation.

La mise en œuvre de ces deux étapes, ainsi que l'utilisation de méthodes de régularisation pour éviter le surajustement ont fait l'objet d'une publication (Kong A Siou, L., *et al.* 2011b) dont le résumé est proposé en français ci-après, suivi de l'article en anglais accepté par la revue Environmental Earth Sciences. Les éléments clés de l'article qui seront utilisés dans la suite de ce manuscrit sont rappelés, en français, à la fin de cette section.

Optimisation de la capacité de généralisation pour la modélisation pluie-débit par réseaux de neurones : cas de l'aquifère du Lez (Sud de la France)

Résumé :

Les réseaux de neurones sont de plus en plus utilisés dans le domaine de l'hydrologie du fait de leurs propriétés d'approximation universelle et de parcimonie concernant les systèmes nonlinéaires. Néanmoins, la présence de bruit et d'incertitude dans les données hydrologiques qui, dans certains cas, peuvent être importants, rend ces modèles particulièrement sensibles à l'augmentation de leur complexité. Le compromis connu sous le nom de dilemme biais-variance en apprentissage statistique, peut être résolu en utilisant des méthodes de régularisation. Suivant la présentation du dilemme biais-variance, ainsi que des méthodes de régularisation telles que la validation croisée, l'arrêt précoce et la modération des poids, une application est ensuite proposée pour simuler et prévoir le débit sortant de l'aquifère karstique du Lez. L'efficacité du processus de régularisation est donc démontrée sur un bassin non-linéaire et pour partie inconnu. En dernière partie, les résultats sont présentés sur l'évènement pluvieux le plus intense de la base de données, permettant ainsi d'évaluer la capacité du réseau de neurones à généraliser sur des évènements rares ou extrêmes.

Optimization of the generalization capability for rainfall-runoff modeling by neural networks: The case of the Lez aquifer (southern France)

Line Kong A Siou^{1,2}, Anne Johannet¹, Valérie Borrell Estupina², Séverin Pistre²

¹Ecole des Mines d'Alès, CMGD, 6 avenue de Clavières, 30319 Alès Cedex, France ²Université Montpellier II, Hydrosciences Montpellier, Place E. Bataillon, 34095 Cedex 5, France

<u>Abstract.</u> Neural networks are increasingly used in the field of hydrology due to their properties of parsimony and universal approximation with regard to nonlinear systems. Nevertheless, as a result of the existence of noise and approximations in hydrological data, which are very significant in some cases, such systems are particularly sensitive to increased model complexity. This dilemma is known in machine learning as bias-variance and can be avoided by suitable regularization methods. Following a presentation of the bias-variance dilemma along with regularization methods such as cross-validation, early stopping and weight decay, an application is provided for simulating and forecasting karst aquifer outflows at the *Lez* site. The efficiency of this regularization process is thus demonstrated on a nonlinear, partially unknown basin. As a last step, results are presented over the most intense rainfall event found in the database, which allows assessing the capability of neural networks to generalize with rare or extreme events.

Keywords: Neural networks, rainfall-runoff modeling, bias variance dilemma, weight decay, early stopping, karst.

1. Introduction

Karst aquifers cover about 20% of the landscape and constitute a large freshwater reservoir. Yet due to their considerable heterogeneity, karsts behave in a manner that is particularly difficult to comprehend and forecast (Bakalowicz 2005) relative to both flood predictions and water resource characteristics. In the case of heavy rainfall in a Mediterranean setting, this difficulty becomes exacerbated by the interaction between underground and surface flows (Jourde *et al.* 2007; Bailly-Comte *et al.* 2008). In France, major flood events such as *Nîmes* (1988), *Vaison-la-Romaine* (1991), *Aude* (1999), *Gardons* (2002), and *Var* (2010) have now made it mandatory to conduct forecasts for such events. In order to mitigate flood risks, the Ministry of Ecology, Energy and Sustainable Development created in 2003 the National Center for Flood Forecasting and Warning (known by its French acronym SCHAPI), along with 22 regional forecasting units. SCHAPI identifies four types of flood events: slow plain floods, fast floods, estuarine floods, and water table floods. More recently, flooding in karst aquifers has been investigated; as part of such an investigation, the pilot basin selected for discussion in this paper was the *Lez* aquifer.

To better handle the major nonlinearities found in the rainfall-runoff relation, which tend to be even more pronounced in karst basins, neural networks are viewed favorably (Johannet *et al.* 1994); they provide a valuable extension of the systemic approach proposed by Mangin (1975). Many studies have produced satisfactory results for hydrological issues treated using artificial neural networks (Maier and Dandy 1999; ASCE Task Committee on the Application of Artificial Neural Networks in Hydrology 2000a,b); however, the major concern with machine learning, i.e. the bias-variance dilemma, is typically neglected. As a consequence, results are very often overestimated. Specifically, validation data, network complexity and training process must all be chosen using proven methods.

This paper will thus propose, in the next section, a presentation of rainfall-runoff modeling using neural networks, the major issues involved and the tested regularization methods for treating the bias-variance dilemma. The complexity of the *Lez* basin will be discussed in the subsequent section, exposing a total of four difficulties: i) the existence of several springs, yet only one of which has instrumented (*Lez* spring); ii) geological heterogeneity; iii) heterogeneity in rainfall data; and iv) an external influence on its behavior due to the utilization of this major spring for supplying drinking water to the Montpellier metropolitan area (300,000 population). The characteristics and data available on the *Lez* basin will also be provided, then followed by a section devoted to neural model selection and to a generalization optimization procedure for the *Lez* spring discharge simulation. Regularization methods will be compared in terms of performance. In a concluding section, the results of simulation and forecasting exercises without any information on future rainfall trends will be offered.

2. Neural networks for rainfall-runoff modeling

2.1. Introduction to neural modeling

The first studies on rainfall-runoff identification by neural networks were conducted in the 1990's; these were primarily carried out using a multilayer perceptron (Halff *et al.* 1993; Johannet *et al.* 1994). Focused on the properties of both universal approximation (Hornik *et al.* 1989) and parsimony (Barron 1993), these studies exhibited a number of advantages in modeling nonlinear relations of hydrological systems in general and karst systems in particular (Maier *et al.* 2010).

Numerous studies have been carried out for the purpose of comparing the multilayer perceptron model (featuring the universal approximation property) with more conventional approaches towards the conceptual model (Hsu *et al.* 1995; Zealand *et al.* 1997; Sajikumar and Thandaveswara 1999; ASCE Task Committee on the Application of Artificial Neural Networks in Hydrology 2000b). These authors all generally concluded that results were similar, with artificial neural networks showing several advantages, such as the capacity to manage missing data and enable real-time forecasting. For these reasons, neural networks have become increasingly widespread in the field of hydrology.

Along with the rising number of studies was the number of warnings issued that Artificial Neural Networks (ANN) were not suitable for hydrology. Some of the citations include: "ANN are a prisoner of their training data" (Minns and Hall cited by Schmitz and Cullman 2008), "The data available in hydrology can support only the development of models with limited complexity"

(Gaume and Gosset 2003). On the other hand, several research programs produced results that appeared to be unduly optimistic: in some cases, the basin was very small (2 and 20 km²), which served to simplify the rainfall-runoff relation (Sahoo et al. 2006), while in others the model was not evaluated on an independent dataset (Bowden et al. 2002). Recent studies involving model complexity control, variable selection, regularization and independent testing indicate that the generalization capabilities of hydrological neural networks model can be evaluated with a reliability measure (Toukourou et al. 2011). As suggested by Gaume and Gosset (2003), the main cause of neural network failure is the high number of free parameters, which leads to overfitting the data. This phenomenon is known in machine learning as the "bias-variance dilemma". In other words, for one thing, the error computed on the training dataset does not provide a good estimator of the generalization error; and for another, only the generalization error actually increases with complexity. Regularization methods propose solutions to this problem by making it possible to: i) estimate the generalization error on an independent set (i.e. cross-validation); ii) stop training before reaching a state of overtraining (i.e. early stopping, Sjöberg et al. 1995); and iii) avoid overtraining by means of weight decay (i.e. Geman et al. 1992). These three possibilities will be investigated herein by focusing on the complex karst aquifer at Lez spring.

2.2. Model design

Given the dual properties of parsimony (Barron 1993) and universal approximation (Hornik *et al.* 1989), a multilayer perceptron was chosen to identify the rainfall-runoff relation at *Lez* spring. Such a network is composed of one hidden layer of N_h neurons with a sigmoid activation function and one output layer; in this particular case, the output layer contains just one linear neuron (see Fig. 1). The model was intended for a discrete time kT (where $k \in N+$), with T being the sampling period. Rainfall information was introduced as an input with a sliding window of width w. N_h and w optimal values were selected, as will be explained in Section 4. In addition, information on the previous state of the process (i.e. herein the karst system) could be provided by measured outflow on the previous day $q^p(k-1)$.



Figure 1: The multilayer perceptron approach applied to rainfall-runoff modeling

The input-output neural model was designed based on the work by Nerrand *et al.* (1993):

$$q(k+f) = g_{NN}[q^{p}(k-1), r(k), r(k-1), ..., r(k-w+1)]$$

with q(k+f) being the estimated outflow over forecasting horizon f, $q^p(k-1)$ the observed outflow on the previous day, and $\mathbf{r}(k)$ the rainfall vector introduced as an exogenous model input. g_{NN} is the nonlinear function implemented by the feedforward neural network. It should be noted that this model is capable of simulating dynamic processes, although it is not recurrent since the state variables are not estimated by the model (in this case, $q^{p}(k-1)$).

2.3. Training

The training step entails minimizing a cost function, which depends on both observed and estimated outflows, respectively $q^{p}(k)$ and q(k). The mean square error function is often used; this function (*J*) can be written, at discrete time *k*, as follows:

$$J(\mathbf{c}) = \sum_{k} (q^{p}(k) - q(k))^{2}$$

where $q^{p}(k)$ is the observed outflow and q(k) the simulated outflow at time k. c corresponds to the model coefficient vector.

At present, the most efficient training method is the Levenberg-Marquardt method (Hagan and Menhaj 1994), and it has been used in this study. The interested reader is referred to Dreyfus (2005) for details on the training rules and Levenberg-Marquardt algorithms. Performing training with such an efficient algorithm quickly yields a very good approximation of the regression function with respect to the training dataset, yet it still does not assess the model's capability to generalize such a behavior on other data, namely the validation dataset. In machine learning, this dilemma is known as "bias-variance" and it must be resolved.

2.4. The bias-variance dilemma

The bias-variance dilemma is a major challenge in machine learning. As explained by Geman *et al.* (1992) according to statistical perspective, training constitutes a regression problem; it consists of building a function $g_{NN}(\mathbf{v}, D)$, where \mathbf{v} is the vector of input variables and D the subset of data chosen to perform the training, that is able to make predictions on a validation set. Geman *et al.* (1992) showed that on average over all possible sets D, the expectation between the better possible regression, denoted $R(\mathbf{v})$, and possible predictions $g_{NN}(\mathbf{v}, D)$ (depending on both the model and training sets D) can be expressed as the sum of two terms:

The first term: bias, which is the squared difference between the regression $R(\mathbf{v})$ and the expectation $E_D[.]$ of the model prediction: $(E_D[g_{NN}(\mathbf{v},D)]-R(\mathbf{v}))^2$;

The second term: variance, i.e. the variance of the model prediction calculated over all possible training sets: $E_D[(g_{NN}(\mathbf{v}, D) - E_D[g_{NN}(\mathbf{v}, D)])^2]$.

Geman *et al.* (1992) demonstrated that both terms theoretically evolve in the opposite direction from model complexity, i.e. if bias diminishes with complexity, then variance increases. On the other hand, as the model becomes more complex, the bias drops since the prediction function $g_{NN}(\mathbf{v}, D)$ provides for a better fit with the training data. Consequently, as the model becomes more complex, variance increases. Given that variance is estimated on a validation set different from the training set, one consequence is that the error estimated on the training set is not a good predictor of the error estimated on the validation set, which reflects the generalization capability. This phenomenon is also referred to as overtraining or overfitting. When overfitting

occurs, the model learns "by heart" not only the training set information, but also the specific noise generation for this dataset.

In flood forecasting, the key error is the one assigned to validation, meaning that it is necessary to estimate model quality on a dataset independent of the training set. It's worth noting that this assertion seems to be obvious; nevertheless, it is not always respected, as will be explained in Section 2.5 (early stopping).

In order to manage both the low variance and complexity (which induces low bias), regularization methods have been proposed. The following discussion will clearly show that these methods are capable of efficiently preventing overfitting.

2.5. Regularization methods

The literature distinguishes between two types of methods. Active regularization methods operate on the model during the training step, while passive regularization methods pertain to model selection. As indicated by Toukourou *et al.* (2009), active and passive methods may be used at the same time.

Passive regularization methods

Passive regularization methods consist of selecting a model with improved complexity, which means choosing an adequate number of hidden neurons and, for this study in particular, opting for an appropriate dimension of $\mathbf{r}(k)$, the rainfall vector. One well-known method is cross-validation, and it will be presented below.

Cross-validation

As shown by Toukourou *et al.* (2009), cross-validation enables choosing both the inputs, namely rainfall width (w+1), and the number of hidden neurons N_h . The notion here is to evaluate model quality on a dataset (i.e. the validation set) that is independent from the training set while still considering the entire database. The training set has been divided into V subsets and each of these subsets, taken one at a time, is then reserved as the *validation set*. As a consequence, the training is performed V times on V subsets, thus leading to V different training/validation pairs. A performance criterion is calculated on the validation set for each training, making it possible to calculate the cross-validation score S as follows:

$$S = \xi(\frac{1}{V}\sum_{i=1}^{V}Criterion_{i})$$

 $\xi(.)$ is a function that takes into account the mean criterion. Implemented by several authors, see for instance Dreyfus (2005), S is the square root of the mean quadratic error. In this study, the preferred criterion is the Nash-Sutcliffe criterion (Nash and Sutcliffe, 1970), commonly referred to as the Nash criterion since it is classically used to assess hydrological model performance. As a result, the function ξ is simplified to the identity function, and the validation score is then simply the mean Nash score over the validation sets.

Nash_i = 1 -
$$\frac{\sum_{k=1}^{n} (q^{p}(k) - q(k))^{2}}{\sum_{k=1}^{n} (q^{p}(k) - \overline{q^{p}(k)})^{2}}$$

where $q^{p}(k)$ is the observed outflow, q(k) the simulated outflow and k the discrete time. Ultimately, the higher the cross-validation score, the better the model performance relative to generalization capability. This step allows identifying the preferred model. It is important at this point to mention that since the choice of architecture is decided using the training set by means of cross-validation, another independent set must be disassembled, i.e. the test set, which is used to base the final model performance.

Active regularization methods

Active regularization methods rely on the assumption that overfitting occurs when parameter values start to become excessive. This idea has been introduced in a systematic manner with Support Vector Machines. This phenomenon can be understood, for neural networks, by the following mechanism. When a parameter value is too high, the inputted sigmoid function is saturated (i.e. its value is always equal to ± 1) and, consequently, does not participate in the regression model (when a sigmoid of a particular neuron is saturated, its derivative vanishes and thus the neuron no longer contributes to learning). As a consequence, one neuron is useless and complexity is increased without any benefit. Two active regularization methods are thus used to prevent this phenomenon from occurring in the field of neural networks. Weight decay was introduced by Geman *et al.* (1992); this technique involves adding a penalty term into the cost function J(c). On the other hand, Sjöberg *et al.* (1995) considered that stopping training prematurely offers another way to prevent parameters from assuming high values. Both of these methods will be presented in the following sections and then applied to the *Lez* aquifer as a case study.

Weight decay

Weights, or parameters of the neural model, are modified during training in order to minimize the cost function. The procedure proposed by Geman *et al.* (1992) to prevent these values from becoming too high consists of adding a penalty term into the cost function. Consequently, the minimization of this function induces a minimization in the weights. Denoting J_c as the proposed cost function and MSE as the standard mean square error, this function can be written as:

$$J_c = (1 - \gamma)MSE + \gamma \left\|c\right\|^2$$

where **c** is the model coefficient, or parameters, vector. The balance between the parameters value and MSE is controlled by the hyperparameter γ .

Weight decay is effectively applied in the field of machine learning yet, to the best of our knowledge, has still not been widely used in hydrology. This regularization method thus proves interesting to evaluate.

Early stopping

Sjöberg *et al.* (1995) presented this active regularization method for the purpose of system identification within the field of machine learning. The underlying premise here is that if the training is stopped before parameters can reach high values, then overtraining would be avoided. A supplementary dataset independent from either the training or test set becomes mandatory: it is called the "stop set". This method functions as follows. During training, the cost function is calculated on both the stop set and training set. At the beginning of the training process, both errors decrease (while the Nash criterion increases). At a given time during training, the stopping error begins to increase: this means that the model is no longer able to generalize due to overtraining. The training process is thus stopped. This active regularization method is widely used in hydrology (Coulibaly *et al.* 2000) and has yielded satisfactory results.

3. The Lez karst aquifer

3.1. Location and setting

The Lez karst aquifer is located north of the city of Montpellier (in southern France). Lez spring, a major outlet of the aquifer, is permanent and the Lez River crosses Montpellier from north to south. Other outlets (including Lirou, Restinclières and Fleurette) are seasonal springs that flow during high-rate periods. The boundaries of the Lez aquifer are the Vidourle River Basin to the north and east, the Hérault River Basin to the west, and the presumed southern boundary is the Montpellier "fold", an east-west directed thrust fault. The hydrogeological basin has not yet been defined with accuracy, and this is especially true for the northern boundaries. Nevertheless, Thiery et al. (1983) estimated its area to be 380 km². The karst system occupies a position in limestone of the late Jurassic and early Cretaceous Periods. These formations are often covered, and the aquifer is therefore mostly confined (see Fig. 2). Above the impervious formations covering the main Lez aquifer, secondary perched aquifers appear in Cretaceous and Eocene limestone. The recharge area, including main karst outcrops and swallow holes, has been estimated at 130 km² (Fleury et al. 2008; Dörfliger et al. 2008). The main aquifer contains compartments created by faults, like the Corconne fault that separates the basin into two parts. Exchanges between the eastern and western parts of the aquifer however are poorly known, and moreover these faults can also function as drains (Bérard 1983).



Figure 2: The assumed *Lez* hydrogeological basin boundaries. The dark blue areas correspond to main aquifer outcrops, light green areas are perched aquifers and white areas are impervious formations. The closest rain gauges relative to this basin are shown: *St-Martin-de-Londres*, *Valflaunès* and *Prades-le-Lez*.

Lez spring has been tapped in order to supply drinking water to the city of Montpellier. In 1982, boreholes were drilled to enable pumping inside the main drain of the spring, and this has often contributed to drying up the spring and emptying part of the aquifer during low-flow periods. Yet in order to maintain minimal outflow at the spring, a Public Utility Decree imposes releasing 160 l/s into the river when the spring is dry. Measured discharges at *Lez* spring include both pumped and recovered discharges. These measurements therefore are the sum of natural and man-made discharges. Even if the total amount of water pumped yearly is of the same order of magnitude than the cumulated outflow of the spring (33 million m³ per year on average during the 1997-2005 period), it is interesting to note that in the modeling presented in Figure 1, which is flood-oriented, the man-made discharge information is indirectly included by the way of the previous measured discharge $q^{p}(k-1)$ (measured discharge is natural discharge – pumped discharge).

In addition, the basin climate is Mediterranean and, as such, is subject to intense rainfall during the autumn season: daily precipitation values can reach as high as 650 mm, as demonstrated during the 2002 event in southeastern France. Such high-volume rainfall events, referred to as "Cevenol events" in the south of France, have had catastrophic consequences: the recent event in June 2010 in the Var Department (southeastern France) caused 25 casualties and €600 million in direct damages (www.keraunors.org): French Observatory of Tornadoes and Severe Thunderstorms). The Lez River also experienced high flows during the autumn, which gave rise to 66

a flooding hazard in Montpellier. Major events like those occurring in December 2002, December 2003 and September 2005 have caused widespread damage by flooding residences and destroying bridges, roads and dykes.

In this context, rainfall-runoff forecasting has taken on critical importance in the effort to manage floods in an urbanized basin and supervise water resource within a complex, operating basin.

3.2. Database

Extensive works devoted to the *Lez* aquifer have provided a large database of rainfall and discharge measurements. Measured discharges at *Lez* spring were available over the period from 1987 to 2005, and data from several rain gauges in the basin were also available over the same period. The three rain gauges chosen were either inside or near the basin: *St-Martin-de-Londres*, *Valflaunès* and *Prades-le-Lez* (see Fig. 2). Rainfall time series from these rain gauges have been well correlated (cross-correlation coefficients greater than 0.85). Modeling results were thus not significantly different from one rain gauge to the next; however, slightly better results were obtained using the *St-Martin-de-Londres* data (Kong A Siou *et al.* 2011a). Results derived from the *St-Martin-de-Londres* rain gauge are the ones presented in this paper.

The database was divided into 16 hydrological cycles; one cycle runs from September 1st to August 31st. To apply the early stopping regularization method (see Section 2.5), the database was separated into 3 subsets, namely: training set, stop set, and test set (see Table 1). More details regarding the stop set selection will be provided in Section 4.2. The test set was used to assess model performance; this set must remain independent of both the training and stop sets. To evaluate the network's ability to generalize for extreme events, the cycle including the most intense flood event contained in the database was selected as the test set. The training set comprised the other cycles.

| Dataset | Dates | |
|----------|---|--|
| Test | 1 cycle: 2002-2003 | |
| Stop | 2 cycles: 1993-1994 and 1994-1995 | |
| Training | 13 cycles: 1988-1993, 1995-2002 and 2003-2005 | |

Table 1: Database distribution into the training, stop and test sets

4. Complexity selection for the Lez Basin model

A multilayer perceptron was designed in order to simulate the rainfall-runoff relation at *Lez* spring. Despite the availability of information from three rain gauges, the actual rainfall data was only provided by the *St-Martin* rain gauge due to the fact that it provides slightly better flood forecasts (Kong A Siou *et al.* 2010).

4.1. Model selection by means of cross-validation

In this study, the sliding window of rainfall values applied to the network has been chosen using the cross-correlation analysis proposed by Mangin (1975). The comparison between sliding

windows obtained by cross-correlation and by cross-validation was studied in detail and provided an optimal dimension of 9 days according to the *St-Martin-de-Londres* rain gauge (Kong A Siou *et al.* 2011-a). This 9 days window width means that previous rainfalls have an influence on the discharge increment since 9 previous days. This duration has not the same physical signification than the response time of the basin, which has been proved shorter (3 days), as presented in (Kong A Siou *et al.* 2011-b). The 9 days window width can be explainable by the fact that the flood wave vanishes slowly in underground fractured aquifer compared to surface flooding.

In order to select the complexity, the cross-validation approach (presented in Section 2.5) was applied. For each architecture, between o (i.e. just one linear output neuron without any hidden neurons) and 10 hidden neurons, the cross-validation score was calculated and has been reported in Figure 3. No active regularization method was employed and the training was extended through 300 iterations.



Figure 3: Nash-cross validation score vs. number of hidden neurons (300 iterations of the Levenberg-Marquardt training rule)

Figure 3 reveals a significant decrease in the cross-validation score as of 5 hidden neurons, which illustrates overfitting and a sensitivity relative to N_h . It appears that the complexity of four hidden neurons was optimal in this case. With this configuration, the Nash validation score was near 0.95 (0.96 for the training set), and the Nash criterion on the test set equaled 0.95. Both of these values were excellent. For 8 hidden neurons, the Nash validation score was near 0.90 (0.97 for the training set), and the Nash criterion on the test set amounted to 0.69. The bias-variance dilemma is thus clearly obvious. Moreover, in order to illustrate the overtraining effect, hydrographs of the test set for both 4 and 8 hidden neurons are displayed in Figure 4. The simulated peak of December 2002, which is the most intense of the entire database, has been well represented with 4 hidden neurons. With 8 hidden neurons, the test hydrograph shows oscillations characteristic of the overfitting phenomenon.



Figure 4: a) The simulated hydrograph for an optimal number of hidden neurons ($N_h = 4$). Rainfall measurements are also shown at the top of the graph. The solid line depicts the measured discharge at *Lez* spring, and the dashed line corresponds to the simulated discharge. b) The simulated hydrograph of a model with 8 hidden neurons. Oscillations are due to the overfitting phenomenon. Rainfall measurements are included at the top of the graph. The solid line depicts the measured discharge at *Lez* spring, while the dashed line corresponds to the simulated discharge.

4.2. Regularization method application

In order to assess their respective properties, both weight decay and early stopping techniques have been introduced. Like for the previous section, training was extended until 300 iterations so as to generate comparisons.

Weight decay

Weight decay requires selecting a value for the hyperparameter γ (see Section 2.5), and this choice could only be made after extensive trial and error. A lower hyperparameter value had no effect while a higher value degraded performance. Figure 5 presents the evolution of cross-validation scores either with or without weight decay regularization ($\gamma = 0.01$). The best score was obtained without weight decay; nevertheless, weight decay prevents overfitting to affect significantly the models until 10 hidden neurons had been introduced. The model sensitivity relative to N_h has thus been significantly reduced. This is an important result as regards model selection time, given that assessing each possibility is very time consuming. Hence, this regularization method allows choosing any N_h value greater than or equal to 5 and lower or equal to 10.



Figure 5: Nash cross-validation score vs. the number of hidden neurons: i) without regularization, ii) with weight decay ($\gamma = 0.01$), and iii) with early stopping. The solid line is the score without active regularization, the dashed line corresponds to regularization with weight decay, and the dotted line corresponds to regularization with early stopping.

Early stopping

Early stopping requires a stop set independent of the validation and test sets, as described in Section 2.5. One major concern with this method is the level of model specialization with respect to the stop set. As suggested in the literature (Toukourou *et al.* 2011 and Bowden *et al.* 2002), it is also important to choose a set representative of the database. The method selected in this study to reach such a goal is as follows: during an initial step, the standardized discharge and rainfall index values were calculated for each hydrological cycle. A second step entailed identifying the most representative cycles when their rainfall and discharge index values were closest to o. The cycles 1993-94 and 1994-95 were selected as a stop set according to such a method. As a third step, the cross-validation score was calculated for each of these hydrological cycles in order to assess the network's ability to accurately simulate these cycles. It would prove inefficient for the stop set to be too difficult to simulate since the training process would have to be stopped belatedly, thus eliminating the possibility of efficient early stopping.

Figure 5 shows the evolution in cross-validation scores with or without early stopping. As for weight decay, the best score is obtained without regularization using the optimal complexity value. As is the case with weight decay, early stopping reduces the level of sensitivity relative to N_h . An interesting approach to maintaining parsimony is that the optimal number of hidden neurons (N_h) is lower when using early stopping $(N_h=3)$ than without any regularization or with weight decay. Given such a finding, this method turns out to be more parsimonious. In addition, cross-validation scores obtained by early stopping and weight decay are the same with six or more hidden neurons, thereby suggesting that both active regularization methods were equivalent for highly-complex models.

Moreover, the mean number of stop iterations for the selected model (with three hidden neurons) is equal to 94. The training step was therefore less time consuming when using early stopping rather than full training up to 300 iterations.

Sensitivity to parameter initialization

Another point of interest when using neural networks is the sensitivity to the initialization of free parameters at the beginning of learning. In general, several initializations were conducted with the best one being selected. A consistent way to proceed would obviously be to select the best initialization with cross-validation, similar to the process employed to identify the ideal complexity. The impact of both active regularization methods on the diversity of the solution found relative to initialization is studied as a function of complexity. The rise in the number of free parameters would in fact induce a more complicated cost function with an unsmooth hypersurface and more local minima.

Along these lines, the standard deviation of the cross-validation scores was estimated for over 50 initializations, as reported in Figure 6. From this figure, it is apparent that the diversity of solutions at the end of learning is high when no active regularization has been performed. This diversity was divided by three when weight decay was used and by five in the case of early stopping. Active regularization thus avoids having a wide dispersion in solutions and moreover enables lowering the number of initialization trials.



Figure 6: Standard deviation of the Nash cross-validation score estimated for 50 initializations vs. the number of hidden neurons. The solid line depicts the score without active regularization, the dashed line corresponds to regularization with weight decay, and the dotted line indicates regularization with early stopping.

Discussion

Using the simulation of the *Lez* spring karst aquifer as a benchmark, the sensitivity of this neural network-based model could be assessed. As a second step, the cross-validation regularization method was applied to select the more parsimonious architecture so as to avoid overfitting. This method proved to be highly efficient and brought a low level of complexity with an architecture of 4 hidden neurons.

Following this initial approach, both weight decay and early stopping were introduced as active regularization methods during the training procedure. The behavior they induced was quite similar: the performance in generalization (measured by a cross-validation score) was slightly poorer (less than 0.05 of the Nash cross-validation criterion), although they were able to avoid overfitting very efficiently. The cross-validation score did remain constant while complexity increased.
One difference between these two methods must nonetheless be pointed out: early stopping led to an architecture with 3 hidden neurons vs. 5 hidden neurons with weight decay. In this hydrological basin, early stopping was thus found to be the more parsimonious method.

Regarding the sensitivity to parameter initialization, early stopping provided improvement. The variability in preventing a bad solution from being found after training was in fact reduced; conversely, the better solution is also more readily lost, as shown in Figure 5.

4.3. Results: Simulation and forecasting of the Lez outflows

The model was adopted using the best configuration identified from the previous section when introducing regularization methods. Ultimately, the model included 9 rainfall inputs, corresponding to 9 days of recorded rainfall history. The selected N_h with both cross-validation and early stopping was 3 hidden neurons; the Nash criterion on the test set equaled 0.95, and the simulated hydrograph is presented below in Figure 7.



Figure 7: Rainfall measurements are presented at the top of the graph. The solid line is the measured discharge at *Lez* spring, and the dotted line corresponds to the simulated discharge.

It is worthwhile to note that the major peak of December 2002 was slightly underestimated (error of 17%) as regards rainfall accuracy (only one rain gauge over the entire basin). The other flood peaks were all well simulated.

Forecasting

The previously described complexity selection method was applied for 3 forecasting horizons. For a 1-day forecast, the optimal model was the same as the simulated one. For 2-day and 3-day forecasts, the optimal complexity was 2 hidden neurons instead of 3; the following hydrographs were obtained (Fig. 8).



Figure 8: Forecasted hydrographs from horizon k+1 at the top to horizon k+3 at the bottom. The black solid line corresponds to measured discharge at *Lez* spring, while the dotted line represents the forecasted outflow.

Synthetically speaking, model performance in forecasting is presented in Table 2. As a result of the specificity of this forecasting task, another quality criterion had to be introduced: the persistency criterion (Kitadinis and Bras 1980), which is zero if the forecast does not contribute any information regarding current outflow. This persistency criterion is described as follows:

$$C_{p} = 1 - \frac{\sum_{k=1}^{n} [q^{p}(k+f) - q(k+f)]^{2}}{\sum_{k=1}^{n} [q^{p}(k) - q^{p}(k+f)]^{2}}$$

where f is the forecasting horizon, $q^{p}(k+f)$ the observed outflow at time k+f, and q(k+f) the forecasted outflow at time k+f. This criterion thus compares the model forecast to a "naive" forecast, whereby this naive value proposes as a forecast at time k+f the same signal as that observed at time k: in other words, the discharge does not vary between k and k+f. In addition, the naive prediction lies close to the observed signal when the forecasting horizon is short. In contrast, the naive prediction is not correlated with the observed signal when the forecasting horizon is long. Beating the naive forecast thus becomes an easy task. For these reasons, the results presented in Table 2 indicate that a 2-day advance prediction yields a better persistency criterion value than a 1-day advance prediction.

The Nash criterion and then persistency were both able to take into account the fact that the model did not receive any future rainfall assumption when the forecast was established.

| | k+1 | k+2 | k+3 |
|-----------------------|------|------|------|
| Nash criterion | 0.92 | 0.82 | 0.69 |
| Persistence criterion | 0.46 | 0.53 | 0.40 |

Table 2: Model performance for forecasting with three horizons

Discussion

Thanks to the "black box" representation of neural networks, the forecasting of future discharge without a future rainfall assumption could be implemented. Among all the flood events in the dataset, the largest event of December 2002 was chosen as the test set in order to assess the model's ability to estimate such a rare event. Two modes were chosen:

Simulation mode, where the discharge at discrete time k was estimated using rainfall from time k to time (k-w+1) as well as the previous discharge at time (k-1). As described in Section 4.1, w is the width of the sliding rainfall window.

Forecasting mode, where the discharge at discrete time k+f (with f corresponding to the forecasting horizon) was estimated using rainfall from time k to time (k-w+1) as well as the previous discharge at time k-1, without any future rainfall forecast.

In the simulation mode, it was very satisfying to note that with information from just one rain gauge, the neural model was able to simulate peak flow with a 17% error, thus demonstrating the ability to generalize to a rare event or to an event greater than what was present in the training set. Such ability was undoubtedly due to the rigorous complexity selection method explained and used in this study.

In the forecasting mode, the major peak was represented with 35% and 22% error respectively for the 1-day and 2-day horizons without rainfall forecasts. It is remarkable to note that the peak could be predicted synchronously a full day ahead of time, allowing for early warning of the population. Regularization methods proved their efficiency. It would thus seem possible to strengthen this rigorous model design procedure, through the use of model complexity control, input selection, regularization and independent testing, so as to lead to satisfactory forecasts of extreme or rare events.

5. Conclusion

The attractive properties of neural networks make them popular for use in rainfall-runoff simulation. The generalization concern however, as underscored in the literature, limits modeling capabilities and performance. Following a presentation of both the bias-variance dilemma and the challenges of regularization, a cross-validation approach was successively combined with two active regularization methods: early stopping and weight decay. This methodology was applied to the *Lez* aquifer, which reveals problems of karst nonlinearity, rainfall unpredictability and a component of runoff induced by human activity. In addition, model validation was conducted on an independent test set that included the most intense event from the database in order to assess model performance on rare or extreme events. The cross-validation method enabled choosing the optimal model complexity, yielding very satisfactory test results with a Nash

criterion of 0.95 during simulation. Moreover, both of the active regularization methods led to significantly decreased sensitivity relative to complexity and weight initialization. In this manner and by using regularization with early stopping, model operations become less time consuming. Early stopping slightly decreased the model training time; consequently, the final selected model was designed using cross-validation combined with early stopping, resulting in simulation and forecasting with excellent performance.

Acknowledgments

The authors gratefully acknowledge METEO-France for providing the rainfall datasets, as well as Gilles LeGac from the DIREN Montpellier office for generating the discharge data. We are very appreciative of Nathalie Dörfliger, Perrine Fleury, Daniel Diep, Pierre Roussel-Ragot, Bernard Vayssade and Marc Vinches for their helpful contributions to the discussion. We would also like to thank Dominique Bertin from GEONOSIS for his highly effective collaboration in the design and implementation of the Neural Network simulation tool *RnfPro*.

References

(Se reporter aux references bibliographiques en fin de mémoire)

2.2.1. Éléments clés compris dans l'article

La validation croisée

L'ensemble d'apprentissage, utilisé pour déterminer les valeurs des paramètres du réseau de neurones, ne permet généralement pas d'estimer l'erreur de généralisation puisque, par définition, la généralisation correspond à la capacité du modèle à simuler correctement la relation apprise en utilisant des données jamais rencontrées. La validation croisée (M. Stone, 1974) permet l'estimation de l'erreur de généralisation moyenne sur tout l'ensemble d'apprentissage grâce à la séparation de cet ensemble en V sous-ensembles qui serviront tour à tour de sous-ensembles de validation permettant l'estimation de l'erreur de généralisation (Figure 15).



sous-ensemble de validation

Figure 15 : Sous-ensembles de validation

En général, un sous-ensemble de validation correspond à un évènement pluvieux ou à un cycle hydrologique. La méthode est la suivante :

L'apprentissage est effectué en utilisant V-1 sous-ensembles. Le sous-ensemble restant devenant alors le sous-ensemble de validation.

L'erreur de généralisation, ou la performance du modèle (critère de Nash, critère de persistance, erreur quadratique...), est calculé sur ce sous-ensemble de validation.

Les deux étapes précédentes sont répétées en utilisant tour à tour chacun des sousensembles comme sous-ensembles de validation. On obtient donc V critères notés V_i avec i = 1 à V

L'estimation de l'erreur de généralisation globale correspond à la moyenne des erreurs de généralisation de tous les sous-ensembles. C'est le score de validation croisée :

$$S = \frac{1}{v} \sum_{i=1}^{V} V_i$$

Équation 31

L'arrêt précoce

L'arrêt précoce est une méthode de régularisation (J. Sjoberg *et al.*, 1995), utilisée pour éviter le surajustement. Elle consiste à arrêter l'apprentissage avant la convergence de l'algorithme. Pour cela, un ensemble d'exemples indépendant de l'ensemble d'apprentissage et de l'ensemble de test est nécessaire. Au cours de l'apprentissage, l'erreur de généralisation du modèle neuronal est estimée sur cet ensemble indépendant, appelé ensemble d'arrêt. Au début de l'apprentissage, cette erreur diminue au fur et à mesure que les paramètres sont modifiés pour s'approcher des sorties désirées données en apprentissage. Lorsqu'il y a surajustement, l'erreur de généralisation sur l'ensemble d'arrêt augmente. Il faut donc arrêter l'apprentissage au niveau du minimum de l'erreur de généralisation sur l'ensemble d'arrêt.

Séparation des ensembles de test, d'apprentissage et d'arrêt

La séparation de la base de données disponible en trois ensembles est une étape importante qui peut influer sur les performances du modèle choisi. Comme cela a été présenté, il est nécessaire que ces trois ensembles soient indépendants.

L'ensemble d'apprentissage doit être le plus complet possible afin que le modèle apprenne la diversité de tous les comportements du système. Dans notre étude cet ensemble comprend donc toute la base de données à l'exception de deux cycles hydrologiques : un cycle qui est l'ensemble d'arrêt et un autre qui est l'ensemble de test.

L'ensemble d'arrêt, étant donné le principe de l'arrêt précoce, « spécialise » le réseau : le modèle est sélectionné pour donner les meilleures performances possibles sur cet ensemble. Il doit donc être choisi comme représentant le comportement le plus « courant » de la base de données dont on dispose (M.S. Toukourou *et al.,* 2010). Dans ce travail, l'ensemble d'arrêt choisi comporte un cycle hydrologique, celui qui a les indices centrés réduits de pluie et de débit les plus proches de o, signifiant qu'il s'agit d'un cycle « moyen » (Voir chapitre III Figure 35).

L'ensemble de test doit être choisi en fonction de l'objectif fixé pour la simulation. Nos recherches portant sur les crues de sources karstiques, l'ensemble de test choisi est le cycle hydrologique comportant la crue la plus importante en termes de débit et/ou la seconde crue la plus importante. Ce choix permet donc d'évaluer les performances du modèle à prévoir des crues plus importantes que toutes les crues présentes dans la base d'apprentissage.

3. Modélisation pluie-débit

La dernière partie de ce chapitre est consacrée à l'utilisation des modèles par réseaux de neurones en hydrologie. Compte tenu de l'intérêt que présentent les réseaux de neurones, le champ d'utilisation est très vaste, H.R. Maier et G.C. Dandy (2000) dans leur revue font état de 43 publications concernant la prévision de variables hydrologiques, dont 23 seulement concernant le débit. Les réseaux de neurones sont ainsi utilisés tant pour aborder les problématiques de la qualité de l'eau, de la gestion de la ressource que de la prévision des crues. Néanmoins, dans le

cadre de ce mémoire, nous nous concentrerons sur les applications concernant la modélisation et la prévision de débit ou de hauteur d'eau à un exutoire. Après un tour d'horizon des différentes méthodes utilisées et des résultats obtenus, nous irons plus en détail concernant la modélisation de débits ou de hauteurs d'eau concernant les systèmes karstiques qui sont l'objet de la présente étude.

3.1. Perceptron multicouche pour simuler et prévoir le débit

Comme nous l'avons précédemment évoqué, le perceptron multicouche présente des propriétés intéressantes, de parcimonie et d'approximation universelle, et à ce titre a été plébiscité par les modélisateurs souhaitant simuler et/ou prévoir le débit à un exutoire. Dans la revue de H.R. Maier et G.C. Dandy (2000) citée précédemment, 41 des 43 publications citées utilisent un perceptron multicouche.

Cependant, les travaux investigués utilisent très peu les méthodes de régularisation permettant d'éviter le surajustement, et conduisent ainsi potentiellement à des résultats non-optimaux.

Le second problème est que la séparation de la base de données en plusieurs ensembles indépendants, permettant de valider le modèle sur un ensemble distinct des ensembles d'apprentissage et (éventuellement) d'arrêt précoce lorsque cette méthode de régularisation est utilisée, n'est pas systématiquement effectuée.

Néanmoins, certaines études sont menées rigoureusement et dans la suite de ce paragraphe nous en présenterons plusieurs afin de mettre en avant les performances des modèles par réseaux de neurones pour la simulation des débits à un exutoire, dans différentes conditions d'utilisation de ces modèles.

Pour l'utilisation des réseaux de neurones afin de prévoir les crues, la principale difficulté est la non disponibilité des prévisions de la variable de forçage, c'est-à-dire de la pluie. Contrairement aux modèles hydrologiques qui effectuent une modélisation inspirée par la physique du phénomène, les réseaux de neurones peuvent être utilisés sans prévision de pluie, ni même hypothèse sur les évolutions futures de cette dernière (par exemple l'hypothèse de pluie nulle).

Ainsi, M.S. Toukourou *et al.* (2009) ont effectué la prévision des crues, sans prévisions de pluie, sur des bassins à réponse rapide. Le pas de temps utilisé est la demi-heure. La base de données est séparée en trois ensembles distincts : apprentissage, arrêt, et test. L'apprentissage est effectué avec la règle de Levenberg-Marquardt (voir Annexe B). Deux méthodes de régularisation ont été testées : l'arrêt précoce et la modération des poids. Simultanément, la validation croisée a été utilisée pour permettre une sélection optimale de la complexité du modèle. Les variables d'entrée du modèle sont la pluviométrie ainsi que le débit mesuré aux pas de temps précédents. Le modèle a été testé pour des horizons de prévision de 30 minutes à 5 heures, en utilisant alternativement la modération des poids et l'arrêt précoce afin de comparer ces deux méthodes de régularisation. Les performances du modèle sont données en termes de coefficient de détermination (R²) et de critère de persistance (Voir Chapitre I Equation 19). Les auteurs concluent sur de meilleures performances de l'arrêt précoce pour le problème considéré et les données utilisées. De plus, cette étude met en évidence, pour les crues rapides, la nécessité de la prise en compte des variations spatiales de la pluie, cette dernière pouvant varier spatialement de manière très hétérogène.

Toujours pour les crues rapides, G. Sahoo *et al.* (2006) ont utilisé un perceptron multicouche à deux couches cachées pour simuler la relation pluie-débit sur des bassins versants rapides de petite taille à Hawaï. La règle de Levenberg-Marquardt a été choisie pour effectuer l'apprentissage du réseau. Celui-ci comporte quatre neurones sur la première couche cachée et trois sur la seconde. Sans aucune méthode de régularisation, les auteurs obtiennent des résultats satisfaisants, y compris en généralisation sur l'ensemble de test, indépendant de l'ensemble d'apprentissage. Par rapport à l'étude précédente, il faut noter que ces bassins versants sont de si petite taille (2 à 15 km²) que les erreurs d'estimation de précipitations sont vraisemblablement minimes. La fonction de prévision s'en trouve donc simplifiée.

À contrario M. Campolo et al. (1999) appliquent les réseaux de neurones à la prévision pluie-débit d'une rivière dont le bassin versant est très étendu (plus de 2000 km²). Ils utilisent la rétropropagation pour calculer le gradient lors de l'apprentissage et l'arrêt précoce comme méthode de régularisation. Le réseau est un perceptron à une couche cachée comprenant comme variables d'entrées les pluies spatialisées passées, ainsi que le débit mesuré aux pas de temps précédents. Les auteurs précisent que les données ont été normalisées entre 0,1 et 0,9 ce qui évite la saturation des sigmoïdes des neurones cachés. Trois ensembles de données indépendants ont été distingués (apprentissage, test et validation). Les variables ont été sélectionnées en utilisant la corrélation croisée pluie-débit. La sélection du nombre de neurones cachés est faite par une procédure essai-erreur. Deux modèles ont été distingués : le premier permettant une prévision à court terme (de 1 à 10 jours) et le second permettant une prévision à long terme (audelà de 10 jours). Les auteurs expliquent la décroissance des performances du réseau lorsque l'horizon de prévision augmente par le temps de concentration de leur bassin versant. Le temps de concentration semble en effet être la limite de l'horizon de prévision pour les modèles n'utilisant pas de prévision de pluies. On peut regretter que cette étude sur la prévision n'intègre pas de critère spécifique pour évaluer les performances du modèle en prévision comme le critère de persistance.

3.2. Modélisation fonctionnelle des systèmes karstiques

Les travaux concernant la modélisation des karsts par réseaux de neurones sont assez rares, contrairement en ce qui concerne l'hydrologie de surface. On peut cependant citer B. Kurtulus et M. Razack (2007) qui ont travaillé sur le plus vaste système karstique français : le karst de La Rochefoucauld (Charentes), donc l'exutoire est la source de La Touvre, seconde source de France après la Fontaine de Vaucluse, de par l'importance de ses débits (entre 2 m³/s et 40 m³/s). Le réseau est dirigé, c'est un perceptron à une couche cachée qui utilise en entrée des mesures de pluie brutes (sans prise en compte de l'évapotranspiration) et de débits des jours précédents le jour de la simulation. Les données sont normalisées de façon à être comprises entre 0,1 et 0,9. La règle de Levenberg-Marquardt est utilisée pour réaliser l'apprentissage. La régularisation est faite par arrêt précoce sur un ensemble indépendant des ensembles de test et d'apprentissage. Les auteurs ne disposent que de six années de données. Trois d'entre elles forment l'ensemble d'apprentissage, deux autres sont utilisées pour l'arrêt précoce et la dernière pour le test. Les performances du modèle pour la simulation du débit de la source de La Touvre sont évaluées notamment en utilisant le coefficient de régression R². Les auteurs soulignent la difficulté liée au choix des différents ensembles d'apprentissage, d'arrêt et de test lorsque la base de données est

réduite et les phénomènes non stationnaires. Cette difficulté est d'autant plus sensible que la variable d'entrée est la pluie brute. La solution proposée dans notre étude pour définir ces ensembles a été présentée quelques pages plus tôt (Voir paragraphe 2.2.1. Eléments clés compris dans l'article).

3.3. Au-delà de la boîte noire

L'utilisation des réseaux de neurones comme outil de modélisation de type boîte noire ainsi que le caractère automatique de l'apprentissage conduisent parfois à une défiance vis-à-vis des modèles ainsi obtenus et de leur capacité à généraliser à des événements rares ou extrêmes (N.J. DeVos et T.H.M. Rientjes, 2008). Néanmoins certaines études s'intéressant aux réseaux de neurones sont orientées vers la compréhension de ces modèles. Plusieurs questions sont présentées : peut-on introduire dans un réseau de neurones des connaissances connues *a priori* sur le système afin d'aider à la modélisation ? Le modèle créé comporte-t-il des informations « cachées » liées à une réalité physique au niveau du système hydrologique étudié ? Si oui, comment les extraire ?

3.3.1. Introduire des connaissances a priori

La possibilité de développer une architecture particulière du réseau, de façon à ce que celle-ci reflète les connaissances que l'on a sur la structure du système étudié a été proposée par A. Johannet *et al.* (1994). Les auteurs se sont inspirés du modèle systémique du système karstique proposé par A. Mangin (1975) pour développer un réseau identifiant le fonctionnement de l'aquifère, à partir de la relation pluie-débit (Figure 16). Un premier sous-réseau est dédié à l'évapotranspiration et permet le calcul de la pluie efficace. Un second sous-réseau représente l'infiltration, rapide ou retardée et enfin le troisième sous-réseau représente la zone noyée. Ce dernier réseau est constitué d'un neurone représentant le drain, et d'un neurone représentant les systèmes annexes. La sortie du neurone «systèmes annexes » est bouclée et revient à l'entrée du sous-réseau zone noyée, de façon à représenter les échanges systèmes annexes-drain et le temps de retard induit par le passage dans les systèmes annexes, ces derniers étant des éléments de stockage de l'eau.

Le débit est donc simulé à partir des précipitations mesurées des jours les plus récents (pour l'infiltration rapide) et jusqu'à un historique de *w* jours précédents (pour l'infiltration retardée). Le nombre de jours *w* nécessaire a été déterminé par essai-erreur et le meilleur modèle est obtenu avec 17 jours ce qui est proche du nombre de jours de décalage nécessaire pour que les deux séries (pluie et débit) de ce système soient considérées comme indépendantes (voir le paragraphe 2.2.1. du chapitre l concernant les corrélogrammes croisés).



Figure 16 : Modèle boîte transparente.

En haut : modèle d'un système karstique d'après A. Mangin (1975) et en bas : schéma du réseau de neurones reflétant ce modèle (A. Johannet et al., 1994).

Tous les sous-réseaux sont connectés entre eux. L'article étant ancien, l'apprentissage est effectué en utilisant la rétropropagation. Les entrées du sous-réseau bouclé sont initialisées avec les sorties désirées pour le débit et o pour les systèmes annexes (le stockage est donc considéré comme vide au départ). Les résultats en prévision du débit ont une erreur relative moyenne située autour de 10%, les auteurs précisent que la confrontation des résultats obtenus avec les connaissances hydrogéologiques du système karstique étudié montre que le modèle par réseaux de neurones offre des résultats réalistes, permettant donc éventuellement l'interprétation physique de certaines sorties de neurones ou valeurs de paramètres (par exemple l'infiltration retardée). Plus que les résultats obtenus, la méthode est intéressante car elle permet de contraindre l'architecture du modèle neuronal par la connaissance supposée que l'on a du système physique.

3.3.2. Accéder à des informations « cachées »

Couplage réseau de neurones/modèle hydrologique pour identifier le sens physique des paramètres

A. Jain *et al.* (2004) se sont intéressés à la façon dont le réseau de neurones pouvait reproduire les phénomènes physiques. Pour cela, un même jeu de données a été appliqué pour définir deux modèles pluie-débit : un modèle hydrologique et un modèle neuronal. Les auteurs observent la

valeur de sortie de chaque neurone caché et effectuent la corrélation croisée entre ces sorties et les variables d'entrée. Pour un réseau de neurones particulier, ils observent une corrélation importante entre les débits passés (k-1 et k-2) et la sortie des neurones cachés 1, 2 et 4. Ils en déduisent que ces neurones doivent modéliser le débit de base ou le débit de surface car les débits passés sont une combinaison de ces deux variables. Le neurone 3 semble corrélé à la pluie présente et future, c'est le seul qui soit d'ailleurs corrélé de façon significative avec la pluie. Il peut donc modéliser la pluie efficace ou le processus d'infiltration.

Dans le même état d'esprit, R. Wilby *et al.* (2003) ont généré une série chronologique de débits journaliers à l'aide d'un modèle conceptuel. Après avoir réalisé l'apprentissage d'un réseau de neurones avec cette série, ils ont analysé les résultats de ce dernier, en particulier les sorties des neurones cachés et en ont déduit que les neurones cachés du réseau identifiaient les grandes lignes de processus physiques simulés par le modèle conceptuel.

Si ces deux analyses présentent un intérêt certain, elles ne peuvent par contre pas être généralisées, puisque les fonctions des neurones cachés sont dépendantes de l'initialisation des paramètres. De plus lorsque le processus physique est peu connu, le modèle hydrologique ne peut donner d'informations avec lesquelles confronter le modèle neuronal ; il est donc nécessaire d'adopter une autre méthode si l'on souhaite extraire de l'information physique depuis le modèle neuronal.

Modélisation semi-physique : les boîtes grises

La modélisation semi-physique consiste à développer un modèle qui comprend une part basée sur la connaissance physique des processus et une part conceptuelle. Le modèle sera donc composé d'équations issues de la physique (équation de conservation de la masse, équation de transport...) utilisant des paramètres ayant une signification physique, et d'équations paramétrées dont les paramètres doivent être estimés en fonction des mesures dont on dispose du processus à modéliser.

Un tel modèle a été développé par Y. Oussar et G. Dreyfus (2001) en utilisant un réseau de neurones. Les équations décrivant les processus physiques connus avec suffisamment de précision sont implémentées sous forme de neurones reliés par des paramètres fixes. La nonlinéarité de ces neurones est introduite non pas par une sigmoïde mais par une équation issue du modèle physique. Les autres processus sont modélisés en modèle « boîte noire » et les paramètres associés sont donc déterminés par apprentissage. Les auteurs ont appliqué cette méthode au cas de l'assèchement d'un polymère, celui-ci contenant un solvant volatile. Cette application les a notamment amenés à implémenter les équations de conservation de la masse et du volume. Le modèle a obtenu d'excellents résultats pour la simulation des variables de sorties, à savoir la concentration de solvant restante dans le polymère en fonction du temps.

Boîtes transparentes

Partant du fait que l'apprentissage statistique élabore un modèle où les fonctions et les paramètres ne sont pas séparés, A. Johannet *et al.* (2008b) ont proposé une méthode particulière baptisée « boîte transparente » afin d'extraire de la « boîte noire » des signaux ayant un sens physique. Pour ce faire, un modèle physique postulé doit être proposé sous forme de différents schémas-blocs. Dans un second temps, comme cela avait été réalisé par le modèle 82

neuronal proposé par Johannet *et al.* (1994), chaque sous-fonction physique est représentée par un réseau de type perceptron multicouche. Le réseau est ainsi contraint pour donner des informations ayant un sens physique en sortie de chacun des sous réseaux. On peut ainsi avoir un regard sur un point particulier, interne au système ; dans le cas de l'étude de A. Johannet *et al.* (2008b): le signal d'évapotranspiration.



Figure 17 : Exemple de modèle "boîte transparente".

Le réseau est composé de deux approximateurs universels en parallèle. Le premier est utilisé pour la modélisation pluie-débit, de façon globale : en entrée sont présentées les pluies brutes et la valeur de sortie désirée qui est le débit. Le second approximateur est utilisé pour représenter l'évapotranspiration : en entrée on donne un signal « évapotranspiration *a priori* » : une courbe en cloche, atteignant son maximum en été. La « sortie » de cet approximateur est un neurone caché du réseau, connecté au réseau pluie-débit. Les auteurs ont observé que la sortie du sous-modèle « évapotranspiration » présente une courbe dont le maximum est décalé par rapport à celui de la courbe en cloche initiale. Ce décalage est observé quelle que soit l'initialisation des paramètres et le nombre de neurones cachés choisis, les auteurs en concluent que la fonction ainsi produite permettrait de représenter l'évapotranspiration conditionnant la relation pluie-débit.

4. Conclusion du Chapitre II

Nous avons présenté dans le premier chapitre de ce mémoire la difficulté de l'étude des karsts de par leurs caractéristiques non stationnaires et non linéaires. En particulier l'approche systémique proposée par A. Mangin a permis de définir des méthodes génériques s'appliquant à ces systèmes afin d'en extraire de la connaissance.

L'étape complémentaire à ces travaux est naturellement la réalisation d'un modèle hydrodynamique permettant de simuler ou de prévoir les débits à un exutoire karstique. Pour réaliser ce modèle nous avons pensé que les réseaux de neurones, boîtes noires réalisant un apprentissage statistique pour l'identification de fonction grâce à une régression non-linéaire, étaient de bons candidats.

Ce chapitre s'est donc proposé d'exposer la définition, la mise en œuvre et le fonctionnement des réseaux de neurones pour l'identification de la relation pluie-débit. Pour cela, le réseau perceptron multicouche, plébiscité en hydrologie de surface, a été présenté. En particulier, ses propriétés principales, l'approximation universelle et la parcimonie, sont précieuses pour l'application aux systèmes karstiques dont le fonctionnement est partiellement connu. Le principe de l'apprentissage a ensuite été présenté, suivi du dilemme biais-variance problème au cœur de l'apprentissage statistique. La prise en compte du dilemme biais-variance pour l'identification de la relation pluie-débit d'un système karstique complexe a fait l'objet d'une publication qui a été incluse dans ce chapitre, mettant en lumière les précautions à prendre et les méthodes de

régularisation à appliquer pour éviter le surajustement et garantir de bonnes capacités de généralisation.

À l'issue de la présentation de ces fondamentaux sur les réseaux de neurones, nous avons analysé quelques travaux réalisés pour la simulation et/ou la prévision du débit. Ces derniers nous ont permis de mettre en évidence plusieurs propriétés parmi lesquelles le fait que les réseaux de neurones sont particulièrement utiles pour la prévision des crues, qu'ils peuvent aisément prendre en compte un champ de pluie spatialisé, nécessaire lorsque les précipitations sont spatialement hétérogènes. En revanche plusieurs difficultés ont été soulevées en particulier celle de la validation du modèle et du choix délicat des ensembles d'arrêt et de test.

Enfin, des études plus récentes se tournent vers une « ouverture » de la boîte noire dans le but, non seulement de rendre interprétables les paramètres du réseau de neurones ou les sorties des neurones cachés, mais également de se donner la possibilité d'inclure au sein du réseau de neurones les informations connues sur le système à modéliser. La démarche proposée dans ce travail de thèse s'inscrit dans la droite ligne de ces études et sera présentée dans le chapitre V.

Chapitre III : Le Lez, un système karstique complexe

Avant d'aborder les résultats, à proprement parler, de ce travail de thèse, il convient de présenter l'hydrosystème karstique étudié et les résultats obtenus par les études précédentes. C'est l'objet de ce chapitre. Dans un premier temps une présentation générale du système et de son environnement est proposée, démontrant les nécessités qui poussent encore aujourd'hui à étudier ce bassin, qui a pourtant fait l'objet de nombreuses études. Dans un second temps, les contextes géologique et hydrogéologique seront présentés, avant de passer à une revue des études réalisées sur le fonctionnement de ce système karstique, en particulier les différents travaux de modélisation.

1. Présentation générale du bassin

Depuis les années 1970, date des premières études menées par le professeur J. Avias, la source du Lez suscite l'intérêt des chercheurs, et *a fortiori* des chercheurs montpellierains, géologues, hydrologues, chimistes qui travaillent à son contact immédiat. La proximité de la ville de Montpellier, qui connaissait à l'époque la plus forte croissance démographique nationale (plus de 4%), l'importance de la source en termes de ressource en eau (le débit de la source du Lez est de l'ordre de 1,7 m³/s en moyenne annuelle sur la période 1946-1968, c'est-à-dire la période non influencée par l'exploitation de la source), la grande complexité du fonctionnement de ce système, font sans doute partie des raisons qui expliquent cet intérêt.

De plus, sa position sur le pourtour méditerranéen implique toutes les spécificités propres à cette région : le climat, caractérisé par des étés très secs et des automnes particulièrement humides, soumet les aquifères méditerranéens à de fortes perturbations pluviométriques.

La pression anthropique dans la région méditerranéenne est forte et tend à augmenter encore. Le département de l'Hérault dont fait partie le bassin du Lez comptait près d'un million d'habitants en 2008 contre près de 900 000 en 1999 (Insee).

1.1. Géographie et hydrographie

Le système karstique du Lez fait partie du vaste système des garrigues nord-montpelliéraines compris entre le fleuve Hérault à l'Ouest et le fleuve Vidourle au Nord et à l'Est (Figure 18). Le bassin est assez fortement urbanisé, avec plus de 412 000 habitants pour l'agglomération de Montpellier et une densité de 160 habitants par km² pour le département de l'Hérault qui couvre la plus grande partie de la zone considérée, alors qu'elle est de 114 habitants par km² sur l'ensemble de la France métropolitaine. Le fleuve Lez est long de 26 km et se jette dans la mer Méditerranée après avoir traversé la ville de Montpellier.

1.1.1. Climat : des épisodes pluvieux intenses

L'aquifère du Lez est sous l'influence d'un climat typiquement méditerranéen. Les étés sont chauds et secs : la température minimale en moyenne pour cette saison dépasse les 14° C et la

pluviométrie est la plus basse de l'année avec moins de 40 mm en moyenne. Les hivers sont doux : la température moyenne pour le mois le plus froid (janvier) est de 2°C.

Le cumul annuel moyen de pluies varie entre 700 mm au Sud-Est du bassin (Mauguio) et 1120 mm au Nord-Ouest du bassin (Saint-Martin-de-Londres), en comparaison, la pluviométrie moyenne à Paris est de 600 mm. En termes de répartition temporelle, ces pluies tombent généralement de façon abondante (environ 100 à 140 jours de pluie par an) avec en moyenne 40% du cumul total qui tombe entre les mois de septembre et novembre.

La pluviométrie subit des variations interannuelle qui vont du simple au double sur la période 1979 – 2003 ; par exemple le pluviomètre de Montpellier-Mauguio situé au sud de la ville de Montpellier peut enregistrer moins de 600 mm pour les années les plus sèches (1988 et 1992) et plus de 1200 mm pour les années humides (1995, 1996, 2003).

La région est soumise au vent marin, vent violent du Sud-Est qui est impliqué dans la formation d'orages cévenols ou méditerranéens, qui sont des épisodes pluvieux diluviens se produisant à l'automne (voir paragraphe suivant). De plus, ce vent peut entraîner une surcote marine, c'est-àdire augmenter la crue des fleuves en entraînant une importante montée des eaux à leur embouchure.

Concernant plus particulièrement les précipitations, l'arc méditerranéen est fréquemment soumis à des évènements pluvieux très intenses. Les conséquences hydrologiques de ces épisodes dits méditerranéens peuvent s'avérer catastrophiques : catastrophe du Var en juin 2010 (23 morts, plus de 400 mm de pluie en 24h), inondations du Gard en septembre 2002 (23 morts et plus d'un milliard d'euros de dégâts, près de 700 mm de pluie en 24h) ou encore épisode diluvien de novembre 1999 dans l'Aude qui a causé la mort de 35 personnes, sont autant d'exemples attestant du risque hydrométéorologique présent dans ces zones (E. Gaume *et al.*, 2009 ; F. Vinet, 2008). On distingue deux grands types d'épisodes pluvieux intenses : les épisodes où le forçage orographique est dominant et les épisodes où les forçages atmosphériques sont dominants. L'automne est particulièrement propice à ces phénomènes du fait de la température élevée de la mer Méditerranée.

Dans le premier cas, ce sont des flux marins doux et humides qui viennent buter sur un relief, se présentant généralement perpendiculairement à ces flux. Le soulèvement de cette masse d'air de basse couche et la présence d'éléments d'instabilité en altitude (divergences d'altitude, anomalies froides...) permettent d'initier une convection profonde et durable (24 à 96h) pouvant se positionner du piémont aux crêtes. Ces épisodes sont généralement appelés "épisodes cévenols" du nom du massif des Cévennes qui les voit très souvent se produire en automne. L'initiation du phénomène est directement liée au relief. Ce genre d'épisode influence quelquefois l'extrême amont du bassin d'alimentation de la source du Lez.

Dans le second cas, c'est la dynamique atmosphérique régionale, parfois aidée de forçages orographiques locaux mais non essentiels dans l'initiation et l'entretien du phénomène, qui va permettre à des orages de se manifester. Plus précisément, c'est l'association d'un contexte convergent en basse couche, impliquant une élévation de l'air, et divergent en altitude, impliquant une aspiration de l'air situé en-dessous dans un flux cyclonique (qui tourne dans le sens inverse des aiguilles d'une montre) marqué, qui va déclencher la convection. On explique ce phénomène par un excellent phasage entre convergence au sol et divergence d'altitude. Ces deux 86

éléments en phase permettent la régénération des orages. Dans la plupart des cas, ces orages sont à régénération arrière* ce qui provoque la stationnarité des précipitations très intenses qui sévissent au sol. Parfois, ces orages peuvent adopter des structures particulières : orages « en V » lorsque l'association convergence/divergence stationne plusieurs heures et est parfaitement phasée, ou systèmes convectifs de méso-échelle quand l'orage prend une dimension importante et s'auto-entretient. Les précipitations sont souvent moins durables que dans le cas des épisodes cévenols mais assez nettement plus intenses (parfois près de 150 mm en 1h). Ce genre d'épisode est plus fréquemment rencontré sur le bassin d'alimentation de la source du Lez.



Figure 18 : Hydrographie, bassin versant topographique.

1.1.2. Hydrographie

Plusieurs affluents rejoignent le Lez en aval de la ville de Montpellier (Figure 18) : la Mosson qui est le seul affluent pérenne, le Verdanson, la Lironde tandis que d'autres arrivent en amont de la ville : principalement le Lirou qui lui-même comporte plusieurs affluents (le Terrieu et l'Yorgues notamment). La superficie du bassin versant topographique du Lez à son exutoire est d'environ 540 km², en tenant compte du bassin de la Mosson. Pour le Lez seul, à la station de Lavalette, c'est-à-dire à l'entrée de la ville de Montpellier, le bassin versant topographique a une superficie de 120 km² environ.

1.2. Exploitation de la source du Lez

La source du Lez forme une vasque profonde d'environ 7 m, alimentée en eau par un conduit naturel qui débouche au fond de la vasque et sera par la suite désigné comme le drain principal de la source (voir Figure 20). Le débordement de la vasque au-dessus d'un seuil (voir Figure 22 à Figure 24) donne naissance au Lez. Ce paragraphe retrace l'historique de l'exploitation de la source du Lez et donne les principaux éléments du mode actuel d'exploitation, dit en « gestion active ».

La source est exploitée à partir du XIX^{ème} siècle. L'exploitation était alors « passive » et consistait en une conduite placée au niveau de la vasque et soutirant l'eau par gravité. Les prélèvements gravitaires, donc sans pompage, étaient au départ de 25 L/s et ont évolué jusqu'à atteindre 600 L/s. Cette exploitation gravitaire s'est poursuivie jusqu'en 1968.

A partir de 1968, des pompes sont installées directement dans la vasque que forme la source, à 7 m de profondeur. Le débit maximal prélevé s'élève alors à 800 L/s. La ressource concerne alors des réserves situées sous la cote de débordement de la vasque, c'est-à-dire non sollicitables naturellement (Voir Figure 24).

L'exploitation dite en « gestion active » débute en 1982. De nouvelles pompes sont installées, via des forages, dans le drain principal alimentant la vasque (voir Figure 20), permettant ainsi de solliciter une plus grande part de l'aquifère. Quatre forages ont été creusés, trois sont équipés de pompes et le dernier sert de piézomètre (Voir Figure 19).



Figure 19 : Tête de forage dans l'usine souterraine d'exploitation de la source du Lez.

Ce forage ne contient pas de pompe, permettant l'introduction d'appareils de mesures ou éventuellement de plongeurs pour l'exploration des conduits immergés du karst ou la réparation des installations immergées.



Figure 20 : Schéma du dispositif du captage de la source du Lez.

Les conditions d'exploitation de ces pompes sont fixées par la Déclaration d'Utilité Publique (DUP) du 5 juin 1982. Le pompage maximum autorisé est de 1700 L/s avec un rabattement maximum de 30 m ce qui correspond à une piézométrie minimale de 35 m NGF* dans le piézomètre voisin des forages contenant les pompes.

Par ailleurs, la DUP impose un débit réservé de 160 L/s, ceci afin de maintenir un écoulement dans la partie aval du fleuve toute l'année (l'écoulement dans la partie aval, à partir de l'entrée de la ville de Montpellier, est assuré par un apport de l'eau du Bas Rhône). Lorsque le débit à la source de Lez est inférieur à 160 L/s, le débit restitué est de 160 L/s (Voir Figure 21). Si le débit à la source est supérieur, aucun débit n'est restitué.



Figure 21 : Canal de restitution du débit réservé.



Figure 22 : Débordement de la vasque de la source du Lez.



Figure 23 : Source du Lez à sec au mois de Juillet 2011.



Figure 24 : Vasque de la source du Lez à sec et anciennes installations de pompage.

Ce mode d'exploitation conduit, surtout en été, à une exploitation intense de l'aquifère qui devient donc très déprimé à la fin de l'été. Cependant, les fortes pluies de l'automne permettent de retrouver un niveau piézométrique équivalent au niveau naturel. La vasque de la source du Lez déborde alors à nouveau, et les réserves jusqu'alors sollicitées sont reconstituées. C'est le principe de la gestion active. Les conséquences de ce mode d'exploitation sur le fonctionnement de l'aquifère seront discutées plus en détail par la suite, dans la partie 3 de ce chapitre.

Les enjeux de l'exploitation du bassin du Lez sont donc multiples. D'une part la région est confrontée à une explosion de la demande en ressource en eau, en été particulièrement, et d'autre part l'automne très pluvieux peut avoir également des conséquences catastrophiques. En effet la nature karstique du bassin, associée à d'intenses précipitations, rend difficile la prévision des crues. De plus, l'artificialisation du débit à la source du Lez ajoute une difficulté à l'étude du système naturel. C'est pourquoi de nombreuses études concernant le système du Lez ont été entreprises jusqu'à présent.

2. Contexte géologique et hydrogéologique

2.1. Lithologie et contexte tectonique

Les principaux types de terrains rencontrés sont essentiellement carbonatés : calcaires, calcaires marneux et marnes, d'âge crétacé supérieur et jurassique. On trouve également les sables et conglomérats de l'Oligocène plutôt au Sud du bassin (Figure 27). La succession des niveaux géologiques est présentée dans la Figure 25. Le principal ensemble aquifère est constitué de calcaires de la fin du Crétacé (Berriasien) et du Jurassique. La base de l'aquifère principal est constituée de marnes noires du Callovien et de l'Oxfordien et, lorsque l'aquifère est captif, le toit correspond aux calcaires marneux du Valanginien inférieur (voir Figure 25). L'épaisseur totale de l'aquifère serait ainsi comprise entre 500 m et 700 m (G. Marjolet et J. Salado, 1976). Les marnes noires qui forment la base de l'aquifère constituent cependant une couche de faible épaisseur et très fracturée, qui pourrait localement permettre des échanges entre l'aquifère principal et les calcaires et dolomies du jurassique moyen (G. Marjolet et J. Salado, 1976).

D'autres niveaux aquifères secondaires sont présents dans :

- les calcaires miroitants du Valanginien supérieur (50 à 200 m). Ils forment le Causse de l'Hortus, karst perché et séparé de l'aquifère principal par les marnes et marno-calcaires du Valanginien inférieur.

- les calcaires de l'Hauterivien supérieur (100 m) qui affleurent au Nord, accolés à la faille de Corconne

- les calcaires lacustres du Lutétien (50 à 100 m) qui affleurent au Sud du bassin.

| Hydrogéologie | | Etage et faciès dominant | Epaisseur | Remarques | Série | âge (Ma) |
|---------------------------------|------------|--|--|---|-------------------------|-------------|
| Imperméable | - <u> </u> | Colluvions, alluvions | <10m | | Quaternaire | 2 |
| | <u> </u> | Sables et conglomérats | 0 -300m | | Oligocène | 23 34 |
| Aquifère | | Lutétien - calcaires lacustres | | | Focèno | 54 |
| Imperméable | | Vitrollien - marnes roses, brèches | 40-300m | | Eocene | 53 |
| Aquifère | | Hauterivien supérieur Calcaires graveleux | 100m Contact avec l'aquifère du Lez par la faille de Corconne | | | 96 |
| | | Hauterivien inférieur - Marnes | 100m | | | |
| Aquifere | | Valanginien supérieur Calcaires miroitants | 50-200m | Indépendant | Crétacé inférieur | |
| Imperméable ou peu perméable | | Valanginien inférieur 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 | | 125 |
| Aquifère principal | | Kimmeridgien Portlandien calcaires francs et calcaires argileux | 150-250m | | | 135 |
| | | Sequanien - calcaires argileux en petits bancs | 60-100m | | Jurassique | |
| | | Argovien Rauracien - calcaires francs et calcaires argileux | 300m | | supérieur | |
| Imperméable ou peu perméable | | Oxfordien - Marnes bleues | 20-50m | discontinuités tectoniques | | |
| Aquifère | | Callovien - Marnes et calcaires marneux | 80-100m | | | 151 |
| | | Bathonien - Calcaires à chailles dolomies | 50-300m | | luraccique | 154 |
| | | Bajocien Aalénien supérieur Calcaires siliceux, marnes | 100-150m | Perte diffuse vers ce niveau (Combe de Mortiès) | moyen | 175 |
| | | Aalénien inférieur Toarcien Domérien - Argiles, marnes noires | 150-400m | Fort ruissellement (Combe de Mortiès) | Jurassique inférieur | 175 |



Les âges dans la colonne de droite sont indiqués en millions d'années (Ma).

Du point de vue tectonique, la région a été affectée par deux évènements majeurs : la compression pyrénéenne pendant l'Eocène, et une distension due à l'ouverture du golfe du Lion à l'Oligocène. Il en résulte plusieurs accidents tectoniques profonds et d'extension plurikilométrique qui ont une incidence majeure sur les écoulements au sein de l'aquifère. Les failles peuvent faire une barrière aux écoulements mais aussi être le siège de drains favorisant les écoulements. La limite Sud du bassin est généralement considérée comme correspondant au « Pli » de Montpellier (P. Bérard, 1983 ; Y. Karam, 1989). La coupe schématique présentée en Figure 26 représente cet accident tectonique qui date de la compression pyrénéenne (- 45 Ma environ).



Figure 26 : Coupe schématique générale du bassin du Lez d'après M. Bonnet et M. Mattauer (2010).

La compression pyrénéenne dirigée globalement Nord-Sud est à l'origine de déformations d'axe Est-Ouest affectant les couches jurassiques situées au Sud de la zone d'étude. Plissées, faillées, ces couches chevauchent vers le Nord une écaille de Vitrollien (brêche) qui forme une discontinuité entre ces calcaires déformés au Sud et les mêmes calcaires présents plus au Nord sous les couvertures oligocènes. C'est cette discontinuité qui formerait la limite Sud du bassin d'alimentation de la source tel que proposé notamment par Y. Conroux (2007) et représenté en Figure 27.



Figure 27 : Carte géologique simplifiée du bassin du Lez.

Durant la compression pyrénéenne, plusieurs plis et décrochements voient le jour, formant ainsi le Pic-Saint-Loup, plus haut relief de la région, et de nombreuses failles telles que la faille de Corconne, accident majeur qui traverse le bassin de part en part avec une direction Nord-Est Sud-Ouest (Figure 27). La phase d'extension à l'Oligocène (- 28 Ma environ) de direction Nord-Ouest Sud-Est a sollicité une nouvelle fois ces failles qui sont alors devenues des failles normales. Des demi-grabens se sont formés au Sud du bassin, créant les bassins d'effondrements d'Assas, de Saint-Mathieu-de-Tréviers et de Prades-le-Lez (Figure 27).

2.2. Hydrogéologie et karstification

2.2.1. Phases de karstification

Les différents niveaux calcaires présents dans le bassin se sont karstifiés grâce aux différents épisodes tectoniques qui ont affecté ces niveaux et aux variations eustatiques. La plupart des études concernant le Lez mentionnent cinq phases de karstification qui ont successivement eu lieu au Crétacé moyen, Eocène, Miocène, Pliocène et Quaternaire ancien, et pour finir une dernière phase au Quaternaire moyen et récent (G. Marjolet et J. Salado, 1976). A l'époque de cette étude, l'un des épisodes les plus importants de la karstification des aquifères mediterranéens, la crise messinienne, était encore mal connu. Cette phase majeure de karstification a été mise en évidence dans les années 1980. A la fin du Miocène et au début du Pliocène, la fermeture du détroit de Gibraltar conduit à un assèchement de grande ampleur de la mer Méditerranée. Celle-ci s'abaisse d'environ 1500 m (G. Clauzon, 1982) conduisant ainsi les cours d'eau du pourtour méditerranéen, en surface comme en souterrain, à creuser de profondes vallées et galeries pour rétablir l'équilibre eustatique. Ceci a été mis en évidence par P. Audra et al. (2004) pour plusieurs systèmes dont celui de la Fontaine de Vaucluse, la source sous-marine de Port-Miou, et par L. Mocochain et al. (2006) sur quelques systèmes karstiques d'Ardèche. Cette phase est à l'origine de karsts dotés d'une karstification profonde et d'une grande capacité de stockage, dont le système Lez fait partie (M. Bakalowicz, 2008).

2.2.2. Hydrogéologie

Limites du bassin et zones de recharge

Les limites de la zone d'alimentation de la source ne sont pas connues précisément, principalement par manque de connaissance des circulations souterraines, compte tenu de la complexité du bassin. Il est de plus admis que ces limites varient en fonction du niveau de remplissage dans le karst comme le propose Y. Karam (1989). Les études antérieures, comprenant notamment des essais de traçage, permettent néanmoins de connaître les limites approximatives de ce bassin hydrogéologique. Elles ont notamment été compilées par Y. Conroux (2007) pour proposer un contour du bassin du Lez à la station de jaugeage de Lavalette, prenant en compte le bassin d'alimentation de la source du Lez. Ce bassin aurait une extension de 400 km² et est représenté sur la Figure 27. P. Fleury *et al.* (2008) ne conservent de ce bassin que les zones d'affleurement de l'aquifère principal et les pertes (qui permettent une infiltration rapide) pour donner une estimation de la zone de recharge de l'aquifère, c'est-à-dire le bassin d'alimentation de la source du Lez, qui aurait une superficie de l'ordre de 130 km².

Les parties libres de l'aquifère, qui constituent les zones de recharge directe, sont situées essentiellement à l'Ouest, au niveau du causse de Viol-le-Fort et au Nord (partie Sud du massif du Coutach). L'aquifère affleure en quelques endroits à l'Est et au centre du bassin. Le reste de l'aquifère est captif, sous une couverture de marnes et calcaires marneux du Crétacé inférieur, et au niveau des bassins de Tréviers, de Prades-le-Lez et d'Assas, sous une couverture de marnes et de brèches oligocènes (Figure 27). A ces zones d'affleurement, il faut ajouter les infiltrations localisées au niveau des pertes, présentes notamment le long des failles. Ceci laisse donc l'opportunité que des ruissellements se produisent sur les parties imperméables puis s'infiltrent à

la faveur de pertes. C'est ce qui est notamment observé au niveau de la combe de Mortiès (Figure 27). Lors de pluies, un fort ruissellement peut être observé, et cette zone est drainée par le ruisseau du Yorgues qui vient ensuite se perdre au voisinage de la faille de Corconne. De la même façon, le Causse de l'Hortus, en partie drainé par des sources temporaires sur sa bordure Est, peut indirectement contribuer à la recharge de l'aquifère principal. Les sources drainant la partie Est du Causse donnent naissance à des ruisseaux (Brestalou de Lauret et de Claret notamment) qui se perdent à l'approche de la faille de Corconne. Des traçages au niveau de ces pertes démontrent leur relation avec la source du Lez (G. Marjolet & J. Salado, 1976 ; Y. Karam, 1989). A titre d'exemple, un traçage effectué au mois d'avril 1976 par G. Marjolet a consisté en l'injection d'un colorant dans la perte du Brestalou de Claret sur la faille de Corconne. Le colorant est ressorti 12 jours plus tard à la source du Lez. La vitesse apparente de propagation (vitesse considérée pour un trajet en ligne droite) pour ce traçage est de 57 m/h ce qui est assez rapide.

Circulation supposée des eaux souterraines

Les failles et la présence de formations imperméables font de l'aquifère du Lez un karst de type karst barré, et permettent l'apparition des sources du Lez et du Lirou (Figure 28 et Figure 30).



Figure 28 : Source du Lirou à sec en Juin 2010.

Les failles séparent l'aquifère du Lez en plusieurs compartiments. Les échanges d'un compartiment à l'autre sont mal connus et de nombreux essais de traçage ont été effectués afin de connaître au mieux les relations des différents compartiments entre eux, ainsi qu'avec la source du Lez. Une synthèse des travaux réalisés pour déterminer les connexions des différents compartiments de l'aquifère entre eux et avec la source du Lez a été proposée par P. Bérard (1983). Elle est ici présentée sous forme de carte en Figure 29. Sur cette carte sont également positionnés les exutoires secondaires de l'aquifère du Lez, ainsi que des aquifères perchés, qui se situent dans le bassin d'alimentation de la source du Lez ou autour de celui-ci. Seules les circulations principales sont représentées.



Les étoiles correspondent aux principales sources ou pertes et les flèches aux directions supposées de circulation souterraine.

P. Bérard (1983) distingue trois compartiments pour le système du Lez, qui sont ici présentés du Nord au Sud et de l'Ouest vers l'Est.

Le premier compartiment consiste en la partie Nord-Ouest du bassin où l'aquifère du Lez est essentiellement sous couverture. Il faut noter à cet endroit la présence du Causse de l'Hortus qui, comme nous l'avons indiqué précédemment, permet l'infiltration des eaux de pluie de manière indirecte dans l'aquifère du Lez. Le Causse de l'Hortus peut être partagé, en ce qui concerne les écoulements souterrains, en deux zones : la partie Ouest alimentant le bassin de l'Hérault par des sources telles que la source de Lamalou, la partie Est alimentant l'aquifère du Lez (Foux de Lauret et de Pompignan). La limite du bassin d'alimentation de la source du Lez n'est donc pas connue précisément pour ce compartiment ; elle est de plus susceptible de varier en fonction du niveau piézométrique. Dans ce premier compartiment, la seule partie où l'aquifère du Lez est libre se trouve au niveau du massif du Coutach, situé tout à fait au Nord du bassin d'alimentation de la source du Lez. Le massif du Coutach est un massif calcaire, dont les eaux sont partagées entre la source du Lez et les sources de Sauve qui donnent naissance au Vidourle. Il n'apparaît donc pas entièrement sur la carte présentée en Figure 27 qui se focalise sur la partie Sud, probablement drainée par la source du Lez. De la même façon que pour le Causse de l'Hortus, la limite entre le bassin d'alimentation des sources de Sauve et celui de la source du Lez est mal connue et évolue en fonction du niveau piézométrique (P. Bérard, 1983; Y. Karam, 1989).

Concernant les circulations souterraines de ce compartiment Nord-Ouest, la relation de ce secteur avec la source du Lez a été démontrée par des traçages réalisés au niveau des pertes présentes dans la partie Nord de la faille de Corconne qui forme la bordure Est du compartiment. Ces traçages, déjà évoqués au paragraphe précédent démontrent le rôle de drain joué par la faille qui conduit les écoulements à la source du Lez (la vitesse de transfert de l'ordre de 50 m/h).

Enfin la présence du Pic-Saint-Loup immédiatement au Sud-Ouest de ce compartiment empêche la communication avec le compartiment du Causse de Viol-le-Fort, situé au Sud-Ouest du bassin d'alimentation de la source du Lez.



Figure 30 : Coupe hydrogéologique simplifiée de l'aquifère du Lez d'après P. Fleury et al. (2008).

Le deuxième compartiment est le plus grand, il est composé de toute la partie Est du bassin d'alimentation de la source du Lez, comprenant la source elle-même et séparée de la partie Ouest par la faille de Corconne. Le compartiment comprend les bassins d'effondrement de Tréviers, Prades-le-Lez et Assas (voir Figure 29) au niveau desquels le karst est totalement sous couverture, et une zone où le karst affleure par endroits, correspondant à la partie Est du bassin d'alimentation de la source du Lez.

Ce compartiment comprend la source du Lez, il reçoit donc de l'eau provenant des deux autres compartiments et en particulier du Causse de Viol-le-Fort.

P. Bérard (1983) évoque également une connexion possible avec le Causse de Pompignan situé au Nord-Ouest du bassin d'alimentation de la source du Lez. Les sources temporaires proches de la source du Lez, par exemple Gour Noir et Fleurettes, sont en relation directe avec la source du Lez et constituent donc des exutoires secondaires au système karstique du Lez.

Concernant les écoulements souterrains dans la partie Nord de ce compartiment, les failles de direction Nord-Est Sud-Ouest situées dans cette zone permettent de drainer les écoulements vers la source. En particulier, le site expérimental du Terrieu (Voir carte Figure 27 et photo Figure 31), équipé de plusieurs forages, a permis d'étudier ces écoulements vers la source du Lez soit par des essais de traçages, soit par l'étude des variations piézométriques dans ces forages, en réponse au pompage à la source du Lez. Les différents auteurs ayant travaillé sur ce site (R. Botton, 1984 ; M. Jazayeri Noushabadi, 2009) concluent à une relation très étroite de ce secteur Nord avec la source du Lez. On peut noter que la relation hydraulique de ce compartiment avec la source du Lez, en

réponse au pompage de cette source a été démontrée vers le nord jusqu'au niveau du piézomètre de Fontanès (voir carte Figure 32). Ce compartiment comprend donc au moins une partie de la zone d'influence du pompage de la source du Lez.



Figure 31 : Forages sur le site expérimental du Terrieu.

 Le troisième compartiment défini par P. Bérard (1983) correspond au Causse de Viol-le-Fort qui est une importante zone d'affleurement des calcaires constitutifs de l'aquifère principal. Il est limité au Sud par le pli de Montpellier et à l'Est par la faille de Corconne. Le causse se poursuit au-delà de la limite Ouest proposée sur la carte Figure 29, cette limite Ouest est approximative car le causse est drainé, à l'Ouest, par la Mosson.

La faille de Corconne joue un rôle d'écran partiel en bloquant une partie des écoulements du côté Ouest vers le coté Est. Ceci est démontré par le drainage de ce secteur en hautes eaux par la source du Lirou qui doit atteindre un niveau suffisant pour déborder pardessus les marnes, mises en contact par la faille (coté Est) avec les calcaires (côté Ouest), comme représenté en Figure 30. De plus, l'expérience récente de traçage conduite par V. Léonardi (HydroSciences Montpellier) dans le cadre du Projet Lez Gestion Multi-Usages, effectuée au printemps 2010, a mis en évidence une circulation profonde au travers de la faille, sous les marnes imperméables (en vert sur la Figure 30). Un colorant injecté à l'aven de la Fausse Monnaie (carte Figure 29) est ressorti 25 jours plus tard à la source du Lez, prouvant ainsi la relation entre le Causse de Viol-le-Fort et la source du Lez. Le traceur a également été détecté à la source du Lirou, 19 jours après l'injection. La vitesse apparente (en ligne droite) de transfert est d'environ 10 m/h pour la source du Lez.

Plus récemment, C. Caetano Bicalho (2010) a conduit une étude hydrochimique qui lui a permis de caractériser différents types d'eau arrivant à la source du Lez, notamment lors des crues. Un type d'eau particulier, géochimiquement évolué, a été identifié. Ces eaux correspondent selon l'auteure à des eaux à signature évaporitique. Les évaporites sont présentes dans la couche géologique datant du Trias, situé en-dessous du Jurassique inférieur qui est la dernière couche représentée sur la Figure 19. Ces résultats mis en relation avec des considérations

hydrogéologiques telles que la présence d'une karstification profonde due à la crise messinienne (voir paragraphe 2.2.1) permettent à l'auteure de proposer la présence d'un compartiment profond de l'aquifère du Lez, sollicité lors des crues de reprise après l'étiage. Les eaux du Lez seraient ainsi un mélange entre les eaux d'infiltration rapide, les eaux de l'aquifère principal et les eaux du compartiment profond.

2.2.3. Instrumentation du bassin et interprétation des séries chronologiques

Le bassin du Lez fait partie de l'observatoire MEDYCYSS (Observatoire Multi-Echelle de la Dynamique des Crues et de l'hYdrodynamique Souterraine en milieu karStique – www.medycyss.org) qui a pour buts l'observation et l'étude des systèmes fracturés et karstiques compris entre le Vidourle et l'Hérault. À ce titre, il bénéficie d'une instrumentation importante répartie sur l'ensemble du bassin. Ce paragraphe présente l'instrumentation et les séries chronologiques disponibles sur le bassin du Lez. On se limitera toutefois aux données hydrométéorologiques, sans donner plus d'informations sur les données physico-chimiques des eaux du système. Le travail récent de C. Caetano Bicalho (2010) pourra cependant être consulté par le lecteur intéressé par ces aspects.

Les séries chronologiques de pluie, de débit et de piézométrie sont présentées avec leurs caractéristiques principales (moyenne, variabilité interannuelle, saisonnalité).

Instrumentation

Les nombreuses études antérieures ont permis de mettre en place un réseau d'instrumentation important sur tout le bassin du Lez et nous disposons donc aujourd'hui de longues séries chronologiques pour différentes variables. La carte présentée en Figure 32 permet de localiser les différentes stations citées ci-après. L'instrumentation comprend trois stations de jaugeages du débit sur le Lez avec un enregistrement des données à pas de temps variable de manière à ne réaliser les mesures que lorsque le signal change.

Nous nous intéressons ici uniquement à la station de la source du Lez qui est l'exutoire du système karstique, les deux autres stations se trouvant plus en aval, au niveau de la ville de Montpellier, enregistrent le cumul des eaux sortant du karst et provenant du ruissellement de surface, qui n'est pas l'objet de cette étude. Un réseau de pluviomètres est également disponible, avec essentiellement des données au pas de temps journalier, c'est pourquoi nous travaillerons avec ce pas de temps tout au long de cette étude, même si l'on est forcé d'admettre que cette période d'échantillonnage des précipitations est trop importante au vu de la dynamique du système. Enfin, l'instrumentation comprend un réseau de piézomètres dont les données sont enregistrées automatiquement au pas de temps horaire, en format numérique depuis 2000.



Pluies et débits

Les chroniques de pluie utilisées dans ce travail sont des cumuls journaliers enregistrés par les pluviomètres de Météo-France implantés sur le bassin d'alimentation de la source du Lez ou en bordure de celui-ci. L'observation des chroniques montre, en plus d'une variabilité saisonnière déjà évoquée au paragraphe 1.1.1., concernant le climat méditerranéen, une forte variabilité interannuelle. Le cumul de pluie annuel sur un cycle hydrologique peut passer du simple au triple (par exemple pour Montpellier ENSAM : cumul de 1988-89 = 501 mm et cumul de 2003-04 = 1526 mm).

Les chroniques de débit nous ont été fournies par la DIREN (DIrection Régionale de l'ENvironement) de Montpellier et sont issues du traitement de chroniques de hauteurs d'eau, mesurées un peu en aval de la source au niveau d'un seuil (voir Figure 33).



Figure 33 : Seuil de mesure de hauteurs d'eau de la DIREN en aval de la source du Lez.

La courbe de tarage, permettant la transformation de la hauteur d'eau en débit, nous a également été fournie par la DIREN et a été établie grâce a des jaugeages* pour différentes hauteurs d'eau.

Des évènements survenant au niveau de la station de mesure ou en amont de celle-ci peuvent être responsables du détarage de la station : une hauteur d'eau donnée ne correspond plus au même débit qu'avant l'évènement. Ceci peut être causé par la construction d'un seuil ou d'un barrage en amont ou d'une modification des berges de la rivière par exemple. Dans notre étude, la station de mesure de la source du Lez a été détarée notamment lors de modifications du seuil de débordement de la source du Lez (rehaussement du seuil afin de pouvoir pomper plus d'eau dans la vasque). C'est pourquoi, comme toute courbe de tarage, la courbe de tarage de la station de mesures de la source du Lez a une période définie de validité. La courbe présentée en Figure 34 a été fournie par la DIREN de Montpellier qui est en charge de la station de mesure. Elle est valide pour la période du 01/01/1987 au 31/12/2010 qui nous intéresse dans cette étude.



Figure 34 : Courbe de tarage et jaugeages à la station de mesure de débits de la source du Lez. Les losanges verts correspondent aux points mesurés. La courbe représente la courbe de tarage (DIREN de Montpellier).

On peut constater sur la Figure 34 qu'il n'y a pas eu de jaugeage au-delà de 5 m^3/s . Ce problème est très fréquent lors de l'établissement des courbes de tarage puisqu'il est techniquement

difficile de réaliser des jaugeages lors de fortes crues. La courbe doit donc être extrapolée, ce qui compromet la précision des mesures de débits forts.

Le débit moyen annuel sur la période 1988-2004 et pour des cycles hydrologiques allant de septembre à août varie de 0,4 à plus de 1,5 m³/s. Afin de caractériser les années humides et sèches, un indice centré réduit est calculé comme suit pour chaque cycle hydrologique (septembre à août):

$$I = \frac{V - \bar{V}}{\sigma_V}$$

Avec *I* l'indice, *V* la variable concernée (cumul de pluie ou moyenne de débit pour le cycle hydrologique concerné), \overline{V} sa moyenne sur la période 1988-2004 et σ_V son écart-type sur cette même période. En Figure 35 les indices sont représentés pour chaque cycle hydrologique. La moyenne des indices relatifs à la pluie permet d'avoir un indice global pour la pluviométrie. Les courbes nous permettent d'identifier les cycles hydrologiques les plus humides, les plus secs, ou au contraire les cycles « normaux » c'est-à-dire ayant un cumul pluviométrique et un débit moyen, au regard de la période 1988-2005. Ces informations ont été utilisées pour définir les ensembles de test, d'arrêt et d'apprentissage de notre modèle neuronal présentés aux chapitres II, IV et V.



Les histogrammes présentent la valeur de l'indice des pluies des cinq pluviomètres présents dans le bassin versant du Lez. La moyenne des cinq indices de pluie est présentée par la courbe rouge. L'indice du débit mesuré à la source du Lez pour chaque cycle est représenté par la courbe bleue. Le calcul de ces indices a été détaillé plus haut dans ce paragraphe.

La Figure 35, si elle nous permet d'identifier les cycles plutôt humides ou secs, ne nous renseigne pas sur la présence ou non d'évènement pluvieux remarquablement intenses. Pour cela, le Tableau 1 présente la liste des évènements les plus intenses survenus pendant la période 1988-2006.

| Date Novembre 1988 Novembre | Débit maximal (m ³ /s) 6,7 7,1 | Cumul maximum en 24h pour le pluviomètre ayant enregistré le plus fort cumul (mm/24h) 104 | Cumul total pour le pluviomètre ayant enregistré le plus fort cumul (mm) 208 227 | Pluviomètre ayant enregistré le plus fort cumul Saint-Martin-de- Londres Saint-Martin-de- | |
|--------------------------------------|---|--|---|--|--|
| 1993 Février | 6,5 | 95 | 148 | Londres Prades-le-Lez | |
| 1994 | | | | | |
| Octobre 1994 | 10,6 | 205 | 297 | Saint-Martin-de- Londres | |
| Novembre 1994 | 9,4 | 151 | 230 | Saint-Martin-de- Londres | |
| Décembre 1996 | 10,6 | 186 | 110 | Saint-Martin-de- Londres | |
| Janvier 1997 | 8,5 | 105 | 170 | Saint-Martin-de- Londres /Prades-le- Lez | |
| Décembre 1997 | 11,5 | 117 | 295 | Saint-Martin-de- Londres | |
| Novembre 1999 | 6,9 | 88 | 156 | Saint-Martin-de- Londres | |
| Novembre 2000 | 7,4 | 87 | 143 | Saint-Martin-de- Londres | |
| Janvier | 9,9 | 88 | 151 | Saint-Martin-de- | |
| 2001 | | | | Londres | |
| Décembre 2002 | 15,4 | 161 | 366 | Saint-Martin-de- Londres | |
| Décembre 2003 | 12,6 | 149 | 267 | Prades-le-Lez | |
| Septembre 2005 | 8,8 | 233 | 284 | Valflaunès | |
| Janvier 2006 | 7,9 | 102 | 162 | Saint-Martin-de- Londres | |

Tableau 1 : Evènements pluvieux les plus intenses de la base de données.

Une analyse plus approfondie de ces chroniques sera présentée dans le paragraphe 3, qui concerne la caractérisation du système karstique du Lez, et dans lequel sont présentées les

-

applications des méthodes de corrélations croisées et de débits classés aux données du bassin du Lez.

Piézométrie

Le piézomètre situé au niveau du pompage de la source du Lez permet de mettre en évidence la réaction du système karstique au pompage. La Figure 36 présente la mesure de piézométrie au niveau de la source du Lez, confrontée avec le débit journalier pompé au même endroit. C'est ici l'année 2003 qui est représentée car l'été 2003 a été particulièrement sec. De ce fait, c'est cette période qui a été utilisée comme ensemble de test pour notre modèle dédié à l'estimation de la piézométrie (chapitre IV).

Le graphique met en évidence l'influence du pompage qui provoque un important rabattement du niveau piézométrique à la source du Lez pendant l'été. Les premières pluies d'automne rechargent efficacement le karst puisque le niveau piézométrique revient à son maximum. Ce maximum, situé à 65 m NGF, correspond à la cote de la source. Lorsque ce niveau est atteint, la source déborde. La chronique de piézométrie a donc la particularité d'être soumise à ce seuil : les variations sont importantes en-dessous de 65 m NGF, alors qu'au-dessus de ce seuil les variations sont très faibles, la source du Lez évacuant l'eau par débordement. La relation piézométrie-débit est donc très fortement non linéaire dès que l'on considère les niveaux de hauteur d'eau négatifs par rapport au niveau de débordement de la source.





Les nombreux piézomètres installés dans le bassin d'alimentation de la source du Lez permettent de mettre en évidence différents types de comportement, comparés par plusieurs auteurs au comportement du piézomètre de la source du Lez (Y. Karam, 1989 ; Y. Conroux 2007 ; C. Caetano

Bicalho 2010). Ces auteurs ont regroupé les piézomètres selon deux ou trois groupes comprenant :

- Les piézomètres ayant un niveau piézométrique similaire et subissant des variations similaires au piézomètre de la source du Lez.
- Les piézomètres ayant un niveau piézométrique plus élevé, mais des variations synchrones par rapport au piézomètre de la source du Lez.
- Les piézomètres ayant des niveaux piézométriques différents du piézomètre du Lez, et dont les variations sont généralement décalées dans le temps. Les variations peuvent être synchrones par rapport au piézomètre du Lez pendant certaines crues.

Cependant les différents auteurs présentent des résultats qui ne sont pas cohérents entre eux. Les études n'ayant pas été effectuées sur les mêmes périodes, il est difficile de tirer des conclusions de ces travaux. Par ailleurs, comme le karst est très hétérogène, les mesures piézométriques ne peuvent en aucun cas être extrapolées pour prétendre représenter le fonctionnement d'un compartiment géologique de l'aquifère karstique. La variété des comportements des piézomètres, et des interprétations par les auteurs ayant manipulé ces données, permet cependant de mettre en évidence, une fois de plus, la complexité du bassin.

3. Caractérisation et modèles existants de l'aquifère du Lez

Dans cette troisième partie, les séries chronologiques présentées dans la partie 2 de ce chapitre sont exploitées en utilisant les méthodes issues de l'approche systémique présentées au chapitre I. Cette étape nécessaire permet de caractériser le fonctionnement de l'aquifère du Lez, avant de procéder à la modélisation de son fonctionnement.

Les différents travaux de modélisation du débit de la source du Lez précédant notre étude sont présentés dans un deuxième temps.

3.1. Caractérisation de l'aquifère du Lez par l'approche systémique

L'analyse des courbes de débits classés conduite par Y. Conroux (2007) et N. Dorfliger *et al.* (2008) a permis de caractériser la mise en charge du système qui a pour conséquence la mise en fonctionnement de plusieurs exutoires pour l'hydrosystème karstique du Lez, déjà connus sur le terrain. Par ailleurs, les premières analyses que nous avons conduites dans le cadre de cette étude sont les corrélogrammes simples et croisés, qui ont ensuite permis de dimensionnement le modèle par réseaux de neurones (chapitre IV). Enfin, pour appréhender l'impact du pompage à la source du Lez A. Roesch et H. Jourde (2006) ont conduit une étude portant sur trois évènements pluvieux importants qui a permis de montrer que le karst pouvait écrêter la crue de surface.

3.1.1. Analyse des débits classés

Comme souligné dans l'introduction de ce chapitre, l'action de pomper en profondeur dans l'aquifère du Lez assèche la source durant l'été. Or, dès l'instant où le débit sortant est nul il n'est plus possible de reconstituer le débit naturel de la source par simple addition du débit pompé au débit (nul) de cette dernière.

Cependant, afin d'effectuer l'étude des débits classés sur les différentes périodes d'exploitation de la source, Y. Conroux (2007) et N. Dörfliger *et al.* (2008) ont proposé une reconstitution de la chronique de débits « naturels » à la source, c'est-à-dire sans influence du pompage, à partir des chroniques de débit, de hauteur d'eau et de piézométrie.

En ce qui concerne la période de prélèvements gravitaires, les débits sont simplement reconstitués par ajout du débit prélevé, tandis que pour la période de prélèvement par pompage, un modèle conceptuel de simulation a été mis en œuvre afin de simuler la chronique des débits. Cette chronique de débits dits « naturels » a été utilisée par les auteurs pour effectuer une analyse des débits classés.

Les classes de débit choisies par Y. Conroux (2007) varient de o à 18 m³/s avec une amplitude de 0,1 m³/s. La méthode d'analyse des débits classés a été appliquée sur chaque cycle hydrologique, d'une part, et pour chacune des trois périodes de prélèvement d'autre part (1945–68 ; 1974-82 ; 1982-2005). Dans tous les cas, une augmentation de la pente pour les forts débits est constatée (Figure 37). Cette augmentation est interprétée, comme le suggère B. Marsaud (1997), comme la mise en fonctionnement de trop-pleins, autres exutoires du karst du Lez que nous avons déjà évoqué dans ce chapitre (Source du Lirou, source de la Fleurette etc....).



Figure 37 : Courbes de débits classés par période de prélèvement à la source du Lez d'après Y. Conroux (2007) modifiées avec l'accord du BRGM.

Les débits de 1946 à 1968 sont les débits naturels, de 1974 à 1982 ce sont les débits reconstitués puis ce sont les « débits naturels » simulés. Pour chaque segment de droite la pente est notée α_i.

L'auteur a constaté qu'au sein d'une même période, il n'y avait pas de différence majeure entre les cycles hydrologiques, en revanche, la période 1982-2005, donc après le début du pompage en profondeur présente des droites de plus forte pente pour les débits faibles ou moyens alors que pour les très forts débits la pente est moins forte. Cependant les débits utilisés pour construire les droites correspondant à cette période sont des débits simulés par un modèle, il paraît donc difficile de faire la part entre les modifications dues à l'exploitation de la source du Lez et les
erreurs de modélisation. Il semble donc hasardeux de tirer des conclusions de cette analyse, même si elle semble conforter l'hypothèse que l'aquifère est plus transmissif, dû au décolmatage de fissures lors du pompage.

3.1.2. Corrélogrammes simples et croisés

Corrélogramme simple

Le corrélogramme simple est calculé pour la chronique de débits mesurés à la source du Lez. Par définition il est symétrique par rapport à l'axe des ordonnées, seule la partie droite est donc représentée dans les figures présentant des corrélogrammes simples



Figure 38 : Corrélogramme simple du débit moyen sur la période 1988-2005 à la source du Lez

Sur le graphique présenté en Figure 38, on note que la corrélation du débit mesuré de la source du Lez pour un décalage de o est bien égale à 1. Cette corrélation diminue ensuite quasi linéairement avec l'augmentation du décalage. On peut lire sur le graphique que l'effet mémoire du système karstique du Lez (défini au chapitre I comme le nombre de jours pour lequel la corrélation atteint une valeur de 0,2) est de 64 jours, soit un peu plus de deux mois. En moyenne, le débit à la source du Lez au jour *j* est donc corrélé au débit des jours précédents jusqu'à deux mois précédant le jour *j*.

Corrélogramme croisé pluie-pluie

Les corrélogrammes croisées pluie-pluie sont utilisées pour estimer la variabilité spatiale de la pluie au niveau du bassin d'alimentation de la source du Lez. Les séries chronologiques de pluie enregistrées par les différents pluviomètres présentés précédemment sont donc comparées deux à deux. Un exemple de corrélogramme pluie-pluie est présenté en Figure 39. La valeur de la corrélation pour o jours de décalage correspond à la corrélation des deux pluviomètres comparés.

Le calcul a été effectué pour tous les pluviomètres utilisés dans cette étude. On obtient ainsi, pour chaque couple de pluviomètres, une valeur de corrélation par cycle hydrologique. Le tableau suivant donne pour chaque couple de pluviomètres la moyenne de la corrélation sur tous les cycles hydrologiques de 1988 à 2004.



Figure 39 : Corrélation croisée entre les cumuls de pluies à Prades-le-Lez et les cumuls de pluie journalières à Saint-Martin-de-Londres pour le cycle hydrologique 1988-1989.

| | Valflaunès | Montpellier ENSAM | Pompignan | Saint-Martin- de-Londres | Prades-le- Lez | Montarnaud |
|---------------------------------|------------|----------------------|-----------|-----------------------------|-------------------|------------|
| Valflaunès | | 0,75 | 0,84 | 0,86 | 0,89 | 0,81 |
| Montpellier ENSAM | | | 0,65 | 0,69 | 0,84 | 0,76 |
| Pompignan | | | | 0,83 | 0,78 | 0,71 |
| Saint- Martin-de- Londres | | | | | 0,83 | 0,83 |
| Prades-le- Lez | | | | | | 0,85 |
| Montarnaud | | | | | | |

Tableau 2 : Moyenne des corrélations croisées pluie-pluie pour tous les cycles hydrologiques de 1988 à 2004.

Ce tableau montre qu'<u>en moyenne</u> les cumuls de pluie journaliers entre les différents pluviomètres sont bien corrélés. On pourra donc envisager de ne pas utiliser tous les pluviomètres pour représenter la pluie tombant sur le bassin d'alimentation de la source du Lez, pour une modélisation en continu sur plusieurs cycles hydrologiques. Les cumuls de pluie horaires ont été traités de la même façon pour une quinzaine d'évènements pluvieux. Les résultats montrent que la corrélation entre les pluviomètres est encore forte, même pour un pas de temps court.

Corrélogramme croisé pluie-débit

Les corrélogrammes croisées pluie-débit permettent d'obtenir deux types d'information. D'une part, la comparaison des corrélogrammes obtenus à partir des différents pluviomètres permet de déterminer quels sont les pluviomètres les mieux placés pour effectuer une modélisation pluiedébit. En d'autres termes, quels sont les pluviomètres pour lesquels la corrélation entre la pluie enregistrée et le débit mesuré à la source du Lez est maximale. D'autre part, l'étude du corrélogramme permet de déterminer après combien de jours la pluie est la plus influente sur le débit, c'est-à-dire le temps de réponse sur bassin d'alimentation de la source. Cette analyse a été conduite pour les données dont nous disposons sur le Lez et les résultats ont été utilisés pour construire le modèle pluie-débit par réseaux de neurones. Cette méthode de construction du modèle par réseaux de neurones est présentée au chapitre IV.

Comme précédemment, les calculs sont effectués en considérant chaque cycle hydrologique de septembre à août. La Figure 40 présente le corrélogramme croisé pluie-débit, prenant en compte la pluie à Saint-Martin-de-Londres et le débit à la source du Lez pour le cycle 2003-2004. La corrélation maximale, inférieure à 0,5, est assez faible au regard de la valeur de 0,2 qui est donnée comme étant la valeur pour laquelle deux séries sont décorrélées. Cette valeur maximale est atteinte pour un décalage de deux jours. Le nombre de jours d'influence de la pluie sur le débit est difficile à déterminer car la valeur de 0,2 est atteinte plusieurs fois autour de 5 et 10 jours. Considérant que ces lectures difficiles de graphiques rendaient hasardeuse la détermination du nombre de jours de pluie nécessaires à l'entrée de notre modèle, nous avons préféré calculer les corrélogrammes croisés sur des évènements pluvieux. Ce dernier choix est cohérent, par ailleurs, pour un modèle dédié à la simulation des crues.



Figure 40 : Corrélogramme croisé pluie à Saint-Martin-de-Londres/débit à la source du Lez pour le cycle hydrologique 2003-2004.

Les évènements sont choisis sur la période 1987-2004, de façon à ce qu'au moins l'un des pluviomètres dépasse la valeur de 90 mm/jour. Dès lors, le début de l'évènement est le premier jour de pluie sur l'un des pluviomètres et se termine lorsque le débit est revenu à une valeur proche de sa valeur avant l'évènement ou lorsqu'une nouvelle pluie vient perturber la décrue. Le but était donc d'avoir la réponse du système karstique du Lez à une occurrence de pluie suffisamment intense.

La Figure 41 présente le corrélogramme croisé obtenu pour l'évènement de décembre 2003 avec le pluviomètre de Saint-Martin-de-Londres. Comparativement aux corrélogrammes obtenus avec les cycles hydrologiques entiers, ce corrélogramme pour un évènement est beaucoup plus lisible. La corrélation maximale a également augmenté et est devenue significative au regard du seuil de 0,2 pour lequel les séries sont considérées comme décorrélées. Ce dernier seuil est atteint au bout de 6 jours dans le cas de l'exemple donné en Figure 41.



Figure 41 : Corrélation croisée pluie à Saint-Martin-de-Londres/Débit à la source du Lez pour l'évènement pluvieux de Décembre 2003.

Les corrélations maximales obtenues avec les différentes chroniques de pluie sont reportées dans le Tableau 3. Il s'agit de moyennes pour tous les évènements sélectionnés (15 évènements présentés dans le Tableau 1). De plus, il faut noter qu'en moyenne sur les 15 évènements, les corrélations maximales sont obtenues pour deux jours de décalage pour tous les pluviomètres. Le temps de réaction du bassin d'alimentation de la source du Lez est donc d'environ deux jours. Pour atteindre le seuil de 0,2, huit jours en moyenne sur les 15 évènements sont nécessaires pour tous les pluviomètres. Ces informations seront utilisées pour la sélection des entrées de pluie de notre modèle (voir chapitre IV), il faudra cependant les utiliser avec précaution car il s'agit d'informations obtenues en événementiel et non en continu sur tout l'année.

| Pluviomètres | Prades-le-Lez | Pompignan | Valflaunès | Saint-Martin- de-Londres | Montpellier ENSAM |
|-------------------------|---------------|-----------|------------|-----------------------------|----------------------|
| Corrélation maximale | 0,60 | 0,62 | 0,64 | 0,62 | 0,60 |

Tableau 3 : Moyenne sur 15 évènements des corrélations maximales pluie-débit à la source du Lez

On pourra noter également que comme les pluviomètres sont bien corrélés entre eux, la corrélation maximale avec le débit à la source du Lez ne varie que très peu d'un pluviomètre à l'autre.

3.1.3. Conséquence du pompage en « gestion active »

Le pompage dans le drain principal de la source du Lez permet techniquement une surexploitation de l'aquifère, particulièrement en été lorsque la demande est la plus forte, et alors même que la ressource en eau est la moins abondante. Par conséquent, à l'automne lorsque surviennent les pluies intenses susceptibles de générer des crues importantes et potentiellement dangereuses pour les activités humaines, l'aquifère est très déprimé. Sur ces considérations, on peut donc supposer que le karst peut stocker temporairement plus d'eau de pluie et donc écrêter la crue souterraine, et par conséquent de surface, à condition, bien sûr, que la pluie tombe là où il y a possibilité d'infiltration rapide dans le karst.

A. Roesch et H. Jourde (2006) ont estimé le volume disponible dans le système karstique du Lez pour un stockage de l'eau. Leur étude se base sur les trois évènements particulièrement intenses de notre base de données : septembre 2002, septembre 2003 et décembre 2003 (voir leurs caractéristiques dans le Tableau 1). L'été 2003 ayant été particulièrement sec, le karst était très

déprimé juste avant l'épisode de septembre 2003. Les auteurs ont donc choisi cet évènement comme référence de la quantité maximale pouvant être stockée dans le karst. Ils ont estimé cette capacité de stockage à 20.10⁶ m³, ce qui correspond, par exemple, aux capacités d'écrêtages cumulées des différents barrages du bassin du Vidourle. (*ftp://ftp.sisyphe.jussieu.fr/public/.../20110414_VisiteParis6_Barrages.pdf*)

Le karst peut donc jouer le rôle d'un barrage écrêteur de crue, mais à condition que la pluie soit localisée sur une partie du bassin d'alimentation permettant une infiltration rapide. En effet, si la pluie est localisée sur une zone imperméable, le ruissellement sera important et générera des débits forts au niveau de la crue de surface sans que le karst ne puisse jouer un rôle.

3.2. Travaux de modélisation à la source du Lez

Dans cette partie, un historique des modélisations effectuées à la source est proposé. L'accent sera mis sur les modèles les plus récents.

3.2.1. Modélisation à la source du Lez : un historique

Les premières modélisations ont débuté dans les années 1970, notamment en vue de l'exploitation de la source, avec en particulier les modèles de J. Chemin (1974), le modèle CREC de A. Guilbot (1975) qui permet la simulation des débits mensuels, puis journaliers, à partir de la pluie enregistrée par plusieurs pluviomètres sur le bassin.

Egalement, le modèle **KARINE**, modélisation d'un **K**arst par une **A**ssociation de **R**éservoirs soumis à des INfluences **E**xternes (D. Thiery et P. Bérard, 1984) a été développé spécialement pour la source du Lez afin de simuler le niveau d'eau à la source au pas de temps pentadaire, en vue d'une exploitation. Le modèle a donc été construit de manière à simuler le débit à la source du Lez en prenant en compte le débit prélevé dans l'aquifère. KARINE est l'adaptation au karst du modèle GARDENIA dû également au BRGM et dont la notice peut être consultée (D. Thiery, 2004). KARINE comporte 3 réservoirs : un réservoir superficiel permettant la production de la pluie efficace, un réservoir intermédiaire pour la zone non saturée et un réservoir souterrain représentant la zone saturée qui est connecté à l'exutoire. Ce dernier réservoir, qui constitue la différence majeure avec le modèle GARDENIA, est susceptible de déborder et le débit à l'exutoire est soumis à un pompage. En tout le modèle comporte 12 paramètres. Différents calages ont été effectués en fonction notamment du débit prélevé et de la superficie du bassin d'alimentation considérée. Seuls les critères de performance évalués sur la période de calage sont disponibles et les valeurs atteignent 0,91 au maximum pour le coefficient de détermination R² (D. Thiery et P. Bérard, 1984).

Y. Karam (1989) a proposé dans sa thèse un modèle déterministe* et un modèle stochastique* décrits dans ce paragraphe et reliant la piézométrie mesurée de différents secteurs à la hauteur d'eau à la source. Ces deux modèles ne visent pas tant à donner un débit ou une hauteur d'eau à la source du Lez qu'à interpréter les paramètres de ces modèles en termes de contributions et de circulations hydrodynamiques au sein de l'aquifère. Le modèle déterministe est basé sur le modèle de fonctionnement du karst de A. Mangin (1975) que nous avons présenté au chapitre I. Schématiquement, il considère un drain unique (correspondant par analogie avec le système du Lez, à la faille de Corconne), alimenté ou drainé par des systèmes annexes (différents secteurs du

bassin d'alimentation). Le modèle est appliqué au Lez, hors période de crue pour des raisons de disponibilité des mesures (et de plus les pertes le long du drain-faille de Corconne sont sèches, elles ne constituent donc pas des exutoires secondaires non mesurés). Les extrémités du drain sont représentées par le piézomètre de Claret d'une part pour l'amont, et le plan d'eau à la source du Lez d'autre part pour l'aval. Le modèle utilise ainsi les piézométries relevées à Claret et à la source du Lez pour se caler et donner des contributions supposées de chaque secteur du bassin :

- Zone Nord : massif du Coutach (voir carte Figure 29) et Nord de Pompignan.
- Zone Nord-Ouest : Causse de l'Hortus, limitée par la faille de Corconne à l'Est et le Pic-Saint-loup au Sud.
- Zone Sud-est : Limitée à l'Ouest par la faille de Corconne et au Sud par la limite des bassins d'Assas, de Tréviers et de Prades-le-Lez.

| Hauteur d'eau à la source (m NGF) | 60,70 | 61,90 | 62,80 |
|-----------------------------------|-------|-------|-------|
| Nord | 4 % | 30 % | 85 % |
| Sud-Est | 17 % | 11 % | 1 % |
| Sud-Ouest | 2 % | 2 % | 4 % |
| Nord-Est | 2 % | 2 % | 2 % |
| Nord-Ouest | 75 % | 55 % | 8 % |

Ces contributions sont données dans le Tableau 4.

-

Zone Sud-ouest : Pic-Saint-Loup et Causse de Viol-le-Fort.

Tableau 4 : Contributions de chaque secteur du bassin d'alimentation de la source du Lez en fonction du niveau piézométrique dans le drain principal de la source selon Y. Karam (1989).

Les contributions suggérées par le modèle de Y. Karam (1989) montrent une surprenante inversion en fonction du niveau piézométrique dans le drain. Lorsque le niveau est bas, C'est la zone Nord-Ouest qui prédomine avec 75%, et seulement 4% pour la zone Nord. Lorsque le niveau est haut, la zone Nord passe à 85% alors que la zone Nord-Ouest contribue seulement pour 8%. Il est également surprenant que la région Sud-Ouest (Causse de Viol-le-Fort) ait une contribution très faible alors qu'elle est essentiellement constituée des calcaires de l'aquifère principal et devrait donc directement contribuer à la recharge de l'aquifère. Une nouvelle répartition des contributions sera présentée dans le cadre de notre étude au chapitre V.

Le modèle stochastique est un modèle de type ARMA. Un modèle ARMA(p,q) (Auto Regressive Moving Average) est un modèle auto régressif dont la sortie est donnée par la relation :

$$y(k) = \epsilon(k) + \sum_{i=1}^{p} [a_i \cdot y(k-i)] + \sum_{j=1}^{q} [b_j \cdot \epsilon(k-j)]$$
 Équation 32

y(k) est la valeur observée du phénomène modélisé à l'instant discrétisé k, a_i et b_j sont les paramètres du modèle. Le premier terme $\epsilon(t)$ est un bruit blanc qui suit une loi normale. Le second terme représente le modèle auto-régressif puisqu'il dépend de y(k-1), y(k-2)...y(k-p). p est l'ordre du modèle. Le troisième terme permet de prendre en compte l'influence des perturbations jusqu'au temps k-j.

Le modèle proposé par Y. Karam (1989) permet de reconstituer, à partir des séries chronologiques de débit pompé, les niveaux piézométriques dans l'aquifère lorsque la vasque de

la source du Lez ne déborde pas. Le modèle représente donc le tarissement progressif de l'aquifère, notamment en réponse au pompage de la source, pour les différents compartiments identifiés par l'auteur. Comme pour le modèle dit « déterministe », les épisodes de crue ne sont donc pas traités. Six piézomètres sont pris en compte permettant, selon l'auteur, de représenter les différents compartiments du système.

Karam utilise un modèle ARMA (1,0), c'est-à-dire un modèle AR(1) qui comprend donc 2 paramètres a et b :

 $y(k) = a. y(k-1) + b + \in (k)$

Où y représente la piézométrie estimée dans l'un des piézomètres du bassin d'alimentation de la source du Lez. Six modèles de ce type sont donc mis en œuvre.

L'auteur donne les performances de ses modèles en termes de coefficient de Nash et précise que pour chaque chronique de piézométrie simulée, ce coefficient est supérieur à 0,95.

3.2.2. Modèle de pompage à la source du Lez

Un modèle numérique en deux dimensions a été proposé par M. Jazayeri Noushabadi (2009) pour simuler la réponse hydrodynamique d'un système karstique à un essai de pompage. Le modèle est d'abord développé à l'échelle locale sur le site expérimental du Terrieu, il s'agit d'un modèle à base physique, qui simule l'écoulement de l'eau dans les fractures lors d'essais de pompage. Le réseau de fracture est généré en tenant compte des observations de fracturation effectuées sur le terrain. Une carte de fracturation générée est donc disponible et le modèle peut alors simuler les écoulements souterrains. Ce modèle a ensuite été étendu à l'échelle régionale afin de simuler des essais de pompages à la source du Lez. A cette échelle, le réseau de fractures n'a pas pu être simulé précisément mais le bassin d'alimentation supposé a été divisé en zones de perméabilités différentes, correspondant aux connaissances actuelles concernant ce bassin. Par exemple la zone de la faille de Corconne a été implémentée comme une zone de très forte perméabilité. Le modèle a permis de reproduire assez fidèlement la réaction du niveau piézométrique au pompage sur le site du Terrieu. Pour ce qui est de l'aquifère du Lez, le modèle reproduit les réactions du piézomètre de la source avec plus d'imprécisions.

3.2.3. Modèle VENSIM

Ce modèle est, à notre connaissance, le modèle le plus récent concernant la simulation des débits à la source du Lez et ayant fait l'objet de publication dans la littérature, il sera donc décrit ici avec plus de détails concernant son fonctionnement et les résultats obtenus. De plus comme il est issu d'une approche systémique il sera ultérieurement comparé à l'approche par réseau de neurones proposée dans ce travail (voir le Chapitre IV). Il s'agit d'un modèle global, prenant donc en compte le bassin d'alimentation dans sa globalité sans chercher à reproduire le fonctionnement du bassin maille par maille comme cela serait le cas pour un modèle distribué. VENSIM est un modèle à réservoirs qui fonctionne au pas de temps journalier. Il permet de simuler le débit à la source, ou la piézométrie dans le drain principal au niveau du pompage. Un même calage est envisageable pour ces deux tâches ; c'est ce qui a été réalisé dans l'étude de Fleury *et al.* (2008).

VENSIM est alimenté en entrée par la pluie efficace. Cette dernière est obtenue par le logiciel TEMPO© du BRGM qui permet de calculer cette pluie en deux étapes, en se basant sur le calcul

des corrélations croisées entre toutes les séries chronologiques qui lui sont fournies (débit mesuré, mesures de pluie issues de plusieurs pluviomètres, évapotranspiration):

- Trouver une pondération optimale des pluviomètres utilisés; dans ce cas les trois pluviomètres compris dans le bassin (42,7 % Valflaunès, 18,7 % Prades le Lez et 38.6% St Martin de Londres).
- Déterminer la fraction de la pluie brute qui participe effectivement à l'infiltration : x_{eff} .

Le modèle VENSIM comporte trois réservoirs : infiltration lente, infiltration rapide et zone saturée, qui sont alimentés par la pluie efficace préalablement calculée par TEMPO© (Figure 42). Chaque réservoir reçoit une fraction de la pluie efficace totale (r_{eff}), notée x_i , i = 1 à 3. Dans la suite de ce paragraphe, l'indice 1 sera relatif au réservoir infiltration rapide, l'indice 2 au réservoir infiltration lente et l'indice 3 au réservoir zone noyée. Les paramètres x_1 , x_2 , et x_3 sont déterminés par calage sous la contrainte $x_1 + x_2 + x_3 = 1$

La hauteur d'eau au temps discret k se calcule de la même façon pour les trois réservoirs, qui sont supposés de section constante, on désignera par la suite h_i la hauteur d'eau d'un réservoir et $h_{i,sortant}$ la hauteur d'eau sortant du même réservoir dans l'intervalle de temps t (correspondant au temps d'échantillonage).

$$h_i(k) = h_i(k-1) + x_i r_{eff} - h_{i,sortant}(k)$$
Équation 33

Le débit sortant d'un réservoir au temps k est proportionnel à la hauteur d'eau sortant du même réservoir au même temps k et pendant l'intervalle de temps t. Le coefficient de proportionnalité est la surface du bassin d'alimentation de la source du Lez notée S_{Bv} . Dans cette étude, les auteurs se sont basés sur les études précédentes concernant le bassin du Lez pour fixer cette superficie à 130 km².

Les réservoirs se vidangent tous selon la loi de Maillet, et la variation de la hauteur d'eau dans un réservoir *i* au temps *k* s'écrit :

$$h_{i,sortant}(k) = h_{i,sortant}(0)e^{-k \cdot \alpha i}$$
 Équation 34

où α_i est le coefficient de tarissement pour le réservoir *i*, déterminé par calage.

Ainsi, la hauteur d'eau sortant du réservoir à chaque pas de temps est :

$$\int_{k}^{k+1} h_{i,sortant}(k) = h_{i}(k) \cdot \alpha_{i} \qquad \qquad \acute{Equation 35}$$

Le réservoir « zone noyée » comporte en plus un module de pompage et un seuil de débordement (voir Figure 42). Le module de pompage enlève une hauteur d'eau correspondante au volume d'eau pompé chaque jour, divisé par la surface du bassin versant :

$$h_{pompé} = V_{pompé}/S_{bv}$$
 Équation 36

Le seuil de débordement est déterminé par calage. Au-delà de ce seuil, une fraction $x_{débordement}$ de la pluie est évacuée par les trop-pleins (autres exutoires du système qui ne sont pas mesurés : source du Lirou, source de la Fleurette etc ...) et sort donc du système.

htroppleins= Xdébordement. l'eff

Équation 37

Le débit de la source est égal à la somme des débits sortants des trois réservoirs, auxquels il faut ajouter le débit restitué qui dépend de la hauteur d'eau dans la zone noyée. Le débit restitué est de 160 L/s si $h_3 \le 0$ et de 0 L/s si $h_3 > 0$

Lorsque le modèle simule la piézométrie, il faut ajouter que :

- Si h réservoir > 0 : Piézométrie = $65+(h_3/P_1)$.
- Si h réservoir < 0 : Piézométrie = $65+(h_3/P_2)$.

 P_1 et P_2 sont deux paramètres déterminés par calage et représentant une estimation de la porosité au-dessus et en-dessous du niveau de la source du Lez (qui est de 65m NGF).



Figure 42 : Organisation générale du modèle d'après P. Fleury et al. (2008).

 r_{eff} est la pluie efficace, p est le débit pompé, $q_{i,sortant}$ (i = 1 à 3) sont les débits sortants des réservoirs, x_i , h_i , α_i et $h_{débordement}$ sont les paramètres du modèle définis dans ce paragraphe.

Le modèle comporte donc huit paramètres pour simuler le débit et 10 paramètres pour simuler la piézométrie. Les paramètres sont notés en encadré rouge sur la Figure 42, auxquels il faut ajouter les estimations de porosité utilisées pour la simulation de la piézométrie.

Un même calage est effectué pour le débit et la piézométrie, de sorte que le modèle permette de simuler tour à tour ces deux grandeurs sans changer les paramètres. Les coefficients de Nash obtenus sont 0,80 pour le débit et 0,70 pour la piézométrie. Il faut donc noter que ces performances peuvent être améliorées si l'on décide de caler le modèle sur seulement l'une des deux grandeurs. On note sur l'hydrogramme que le débit est globalement bien simulé à l'exception des pics de crues dont l'amplitude n'est pas toujours bien reproduite. Nous verrons ultérieurement que ce modèle peut évoluer en fonction des besoins (Chapitre IV).



Figure 43 : Simulation du débit à la source du Lez par le modèle VENSIM.

4. Conclusions

Dans ce chapitre nous avons présenté en premier lieu les enjeux importants qui motivent les études de l'aquifère karstique du Lez : la ressource en eau et la prévision des crues. Ces enjeux sont d'autant plus importants que la pression anthropique que subit le bassin s'accentue avec les années.

Dans un premier temps, le contexte géographique et climatique dans lequel se situe le système karstique du Lez a été présenté ainsi que les conditions particulières dans lesquelles son exutoire principal est exploité.

La seconde partie du chapitre a permis de dresser un panorama de la complexité du bassin d'alimentation de la source. L'aquifère karstique du Lez a été présenté comme un aquifère complexe, à la fracturation issue de grands mouvements tectoniques, comportant de ce fait une hétérogénéité géologique. Les travaux précédents ont proposé une analyse hydrodynamique en trois compartiments, et ont permis de préciser les axes de drainages préférentiels. Néanmoins, les échanges entre les compartiments sont encore mal connus, d'autant que la présence d'exutoires secondaires au débit, non mesurés, empêche de définir de manière fiable la superficie du bassin d'alimentation. Ces limites sont, de plus, susceptibles d'évoluer en fonction du niveau d'eau dans le karst.

Dans la troisième partie, nous avons montré comment l'approche systémique a permis de caractériser l'aquifère, notamment en estimant les temps de réponse et d'influence des pluies sur le débit. Ces résultats seront utilisés par la suite pour la mise en œuvre du modèle par réseaux de neurones.

Un historique des modélisations entreprises à la source du Lez par différents auteurs a finalement été proposé. Les modèles sont dédiés à l'étude hydrodynamique de l'aquifère en vue d'une exploitation (Modèle KARINE), ou pour améliorer la compréhension de son fonctionnement (Modèle de Karam, 1989). Dans les deux cas, le problème aigu de modélisation que pose cette source apparaît comme un champ d'application stimulant pour l'apprentissage statistique ; c'est le défi que nous nous proposons de relever dans les deux prochains chapitres de ce mémoire.

Chapitre IV : Modélisation par réseaux de neurones de la relation pluie-débit à la source du Lez

Ce chapitre présente l'application des réseaux de neurones à la modélisation de la relation pluiedébit de la source du Lez. L'objectif est double : il s'agit d'une part d'évaluer la capacité des réseaux de neurones à effectuer les tâches de simulations et de prévisions du débit de la source du Lez en l'absence de prévision des précipitations, et d'autre part de comparer les performances du modèle neuronal de simulation avec celui du modèle VENSIM présenté au chapitre précédent.

Dans la première partie de ce chapitre, deux méthodes de sélection des variables d'entrées du réseau de neurones sont présentées et appliquées au karst du Lez. Ces résultats ont fait l'objet d'une publication (L. Kong A Siou *et al.* 2011a) qui est incluse en début de ce chapitre.

La seconde partie du chapitre concerne la comparaison de deux approches systémiques pour la modélisation du fonctionnement hydrodynamique de l'aquifère du Lez : le modèle neuronal et un modèle à réservoirs, plus classique en hydrologie, qui a déjà été appliqué à des sources karstiques telles que la source du Lez ou la Fontaine de Vaucluse.

1. Sélection de variables et sélection de la complexité du réseau de neurones

Comme nous l'avons indiqué au chapitre II, la méthodologie de conception d'un réseau de neurones comporte deux étapes essentielles : la sélection de variables et celle de la complexité, ou de l'architecture, du modèle.

Une fois le choix du modèle perceptron multicouche effectué, pour ses propriétés d'approximation universelle et de parcimonie, nous nous sommes donc intéressés au choix des variables d'entrée. Disposant de plusieurs pluviomètres sur le bassin versant, la question de la sélection des variables comporte donc deux réponses : d'une part le choix du, ou des, pluviomètres (nous avons vu que pour les modèles utilisant un échantillonnage plus rapide, la pluie spatialisée est nécessaire à une bonne prévision des crues rapides), et d'autre part la définition de la longueur de l'historique des précipitations à prendre en compte pour chaque pluviomètre.

Au chapitre II, la validation croisée a été proposée pour effectuer la sélection de variables et permet tout autant de sélectionner le pluviomètre le plus pertinent, que l'historique des précipitations nécessaires. Néanmoins, nécessitant l'investigation de toutes les configurations possibles, cette dernière ne peut être appliquée de manière exhaustive à l'étude que nous nous proposons de mener du fait de l'explosion combinatoire qu'elle génère.

Pour diminuer le nombre des combinaisons testées nous nous sommes donc inspirés de la méthode proposée par Alain Mangin (1975) pour définir l'effet mémoire, en effectuant la sélection en deux temps :

- Calcul de la corrélation linéaire entre la pluie et le débit pour déterminer l'initialisation de la profondeur de l'historique des précipitations à appliquer pour le pluviomètre considéré.
- Recherche de l'optimum autour de cette initialisation au moyen de la validation croisée.

On peut noter que l'avantage de la validation croisée est qu'elle permet de sélectionner à la fois les variables et la complexité du réseau. De plus, elle prend en compte le fonctionnement non linéaire de l'aquifère, ce que ne fait pas la corrélation linéaire. Enfin, compte tenu du choix du modèle dirigé qui prend en compte comme variable d'entrée le débit observé au temps précédent, l'information de précipitation qui sera retenue est une information nécessaire sur un horizon plus court, puisqu'elle est utilisée, non pas pour calculer le débit, mais seulement <u>l'accroissement</u> du débit par rapport à ce dernier au jour précédent.

Ces considérations sont développées dans la partie qui suit, rédigée sous forme d'une publication parue dans *Journal of Hydrology* le 17 juin 2011 (L. Kong A Siou *et al.* 2011a) et qui est incluse en anglais ci-après. La version française du résumé précède l'article. La publication a été introduite dans son intégralité afin de ne pas compromettre la cohérence du discours qui y est développé et celle des références aux différentes figures et paragraphes. Néanmoins, pour éviter les redondances sur les aspects, notamment bibliographiques, déjà développés dans cette thèse, le lecteur pourra se rendre directement au paragraphe 3.4 de l'article.

1.1. Résumé

Sélection de la complexité d'un réseau de neurones pour la prévision des crues karstiques : cas du bassin du Lez (Sud de la France)

Résumé :

Un modèle par réseaux de neurones est appliqué pour simuler la relation pluie-débit d'une source karstique. La sélection des entrées pour un tel modèle est un problème majeur si l'on souhaite aboutir à un modèle efficace et parcimonieux. Cette étude porte sur la méthode de sélection de ces entrées. Elle commence par exposer deux de ces méthodes, et propose ensuite de les combiner. Les méthodes introduites sont utilisées à la fois en simulation et en prévision. Comme la pluie est très difficile à prévoir, en particulier sur la zone d'étude, nous avons choisi un mode de prévision du débit qui ne nécessite pas de prévision ou d'hypothèses sur la pluie future. Les méthodes sont appliquées à l'aquifère karstique du Lez, un bassin très complexe au vu de sa structure et des conditions dans lesquelles l'opération est menée. Nos modèles ont obtenu d'excellents résultats et les débits prévus à la source du Lez sont acceptables jusqu'à un horizon de prévision de un jour. La combinaison des deux méthodes de sélection des entrées est prometteuse et permet de réduire le temps de sélection des entrées, prenant en compte à la fois la capacité du modèle à gérer la non-linéarité et l'horizon de prévision choisi.

Complexity selection of a neural network model for karst flood forecasting: The case of the Lez Basin (southern France)

Line Kong A Siou^{1,2}, Anne Johannet¹, Valérie Borrell², Séverin Pistre²

¹Ecole des Mines d'Alès, CMGD, 6 avenue de Clavières, 30319 Alès Cedex, France

²Université Montpellier II, Hydrosciences Montpellier, Place E. Bataillon, 34095 Montpellier Cedex 5, France

Abstract

A neural network model is applied to simulate the rainfall-runoff relation of a karst spring. The input selection for such a model becomes a major issue when deriving a parsimonious and efficient model. The present study is focused on these input selection methods; it begins by proposing two such methods and combines them in a subsequent step. The methods introduced are assessed for both simulation and forecasting purposes. Since rainfall is very difficult to forecast, especially in the study area, we have chosen a forecasting mode that does not require any rainfall forecast assumptions. This application has been implemented on the *Lez* karst aquifer, a highly complex basin due to its structure and operating conditions. Our models yield very good results, and the forecasted discharge values at the *Lez* spring are acceptable up to a 1-day forecasting horizon. The combined input selection method ultimately proves to be promising, by reducing input selection time while taking into account: i) the model's ability to accommodate nonlinearity, and ii) the forecasting horizon.

1. Introduction

The need to develop accurate prediction tools for flood events has been underscored by the recent occurrences of catastrophic floods in the northern Mediterranean region, where such events caused at least 4,566 fatalities and $\epsilon_{29,136}$ million in property damage over the period 1990-2006 (Llasat *et al.*, 2010). Between July and September 2002, southern France, Italy and Spain were all affected by fast, or "flash", floods. Flooding is France's leading natural hazard and responsible for major damage; the flooding risk encompasses 20,000 km² of land area, with some 4.5 million residents (8% of the French population) living in flood zones (Source: *France's Ministry of Ecology, Energy and Sustainable Development*). In this country, a number of major flood events have taken place, including Nîmes (1988), Vaison-la-Romaine (1991), Aude (1999), Gardons (2002), Arles (2003) and Var (2010).

In seeking to mitigate flood risks, the Ministry of Ecology, Energy and Sustainable Development created in 2003 the National Center for Flood Forecasting and Warning: SCHAPI (*Service Central d'Hydrométéorologie et d'Appui à la Prévision des Inondations*), along with 22 regional forecasting services (*Services de Prévision des Crues*), which were placed in charge of the "*Vigicrue*" flood monitoring service. This system is based on a round-the-clock watch of the main rivers and generates warning messages broadcast to Civil Security authorities and the local citizenry in the

form of an Internet map (http://www.vigicrues.ecologie.gouv.fr). Four levels of risk are evaluated by tools ranging from simple hydrological analyses to detailed and spatialized hydrological / hydraulic forecasting models spanning a 20,000-km network of river streams. At present, SCHAPI identifies the four following types of floods (for which forecasting techniques still require significant improvements): slow plain floods, fast floods, estuarine floods and water table floods.

Floods in karst aquifers have been investigated more recently; the pilot basin selected was the *Lez* aquifer, which is the topic for the present article. The research work displayed herein has been performed in collaboration with the SCHAPI Unit within the framework of the ongoing project focusing on karsts.

This paper proposes a methodology devoted to the input selection of a neural network model applied to the simulation and forecasting of daily discharges from a karst spring. The first part will discuss the major issues involved in studying karst springs, in order to better understand their behavior, particularly during floods. The case of Mediterranean flash floods, which have caused numerous casualties, will be developed primarily for karst models and flood models. Section 4 will describe neural networks, as an interesting method for karst and flood forecasting by taking advantage of their potential for universal and parsimonious approximations. The key issue of variable selection will be addressed in order to avoid overfitting; moreover, two input selection methods will be presented, with the aim of choosing a rainfall width that explains spring discharge. Based on both these methods, a procedure offering the nonlinear capability of neural networks, while reducing network design time, will be proposed. The paper's final section concerns application of this method to the complex karst aquifer at *Lez* spring. Both simulations and forecasts will be discussed to demonstrate that the method can accurately forecast floods.

2. Context and larger societal issues

2.1. Karst basins

A karst basin is composed of two distinct elements, each of which behaves differently: the surface watershed, and the aquifer. These two components are not necessarily vertically aligned from a geographical standpoint. Moreover, the occurrence of an intense rainfall event is capable of causing surface flooding over a portion of the non-karstified basin, in addition to a rise in the groundwater level over the portion containing karst. Should these two sudden rises in water level coincide, the underground action could exacerbate the surface flood. It is necessary therefore to fully understand the hydrodynamic behavior of both basin components, i.e. karst and non-karst, in order to determine the total extent of flooding. Each karst aquifer is structured differently, as a result of the dissolution of carbonate rock (Bakalowicz, 2005), with different types of underground flows able to coexist. Water flowing within larger drains can reach velocities of several hundreds of meters per hour, while at the other extreme, water flowing through the crack matrix travels much more slowly (with a permeability on the order of 10⁻⁵ or 10⁻⁷). In light of this discrepancy, karst aquifers exhibit nonlinear hydrodynamic behavior that might also include threshold effects, which are naturally difficult to quantify and forecast.

Water infiltration deep into the ground may be either diffused or localized in swallow holes, thus requiring knowledge of the precise precipitation location in order to characterize the karst

recharge. Given the interactions between groundwater and surface water flows, several authors (Jourde *et al.*, 2007; Maréchal *et al.*, 2008; Bailly-Comte *et al.*, 2009) have underscored the importance, along with the difficulties, encountered in modeling and forecasting the flooding that occurs in karst aquifers. Specifically, the karstic portion of the basin is capable of either intensifying the surface flood (via swallow holes found in border springs) or mitigating it, in which case the karst acts like a flood control reservoir. A greater understanding of the hydrodynamic behavior of karst is therefore critical to improving the quality of flood forecasts and helping protect the local population.

2.2. Mediterranean floods

The northern Mediterranean zone is especially concerned by flooding due to its unique climate, which is subject to intense rainfall during the autumn: daily precipitation can reach as high as 650 mm, as demonstrated during the 2002 event in southeastern France. Such high-volume rainfall events, referred to as *Cévenol episodes* in the south of France, have had catastrophic consequences (over 100 fatalities during the past two decades in southeastern France, and $\epsilon_{1.2}$ billion in property damage for the sole event on September 9th, 2002 (Gaume and Bouvier, 2004; Le Lay and Saulnier, 2007). Moreover, the recent event that took place in June 2010 in the *Var* (France) caused 25 deaths and ϵ_{600} million in direct damage (www.keraunos.org: French Observatory of Tornadoes and Severe Thunderstorms).

Rainfall forecasts for the area under investigation lack sufficient accuracy, given that the rain generation process itself has not yet been clearly understood. It remains a difficult task to accurately forecast when or where the next storm will stabilize, even for the most recent meteorological models (such as AROME (Bouttier, 2003)), due to the "backward regenerative system" that feeds the storm with water from the Mediterranean Sea (Delrieu *et al.*, 2005). Flood forecasting models are therefore implemented without accurate rainfall forecasts.

In addition, the issue of karstic basin flood forecasts is not limited to the *Lez* aquifer since 35% of the European territory, primarily the Mediterranean zone, is covered by limestone outcrops.

2.3. Karst modeling and flood forecasting

2.3.1. Karst modeling

Several approaches have been proposed to model karsts and simulate spring hydrographs (see reviews by White, 2002; Bakalowicz, 2008). Reservoir models have been used effectively to simulate spring discharge and flow rate in combination with rainfall data. Several authors (Fleury *et al.*, 2007; Fleury *et al.*, 2008; Jukić and Denić-Jukić, 2009) applied reservoir models to karst-based systems. From knowledge of the overall behavior of karst aquifers, the composition of such models includes several connected reservoirs representing contributions of the saturated zone, the low-infiltration zone and the rapid-infiltration zone, respectively.

Physical models are intended to depict the physical characteristics of karst aquifers. This type of modeling requires extensive system knowledge, which may not always be available due to system heterogeneity. More specific models have thus been developed for karsts. Double-permeability models featuring fracture permeability and conduit permeability have been introduced, for

example, by Mohrlok and Teutsch (1997), Cornaton and Perrochet (2002) and Long (2009). These models consider an average distribution for both the matrix and conduits. More recently, discrete models have taken into account an explicit conduit/matrix system identified through exploration and/or the physical process of conduit development (Mohrlok and Sauter, 1997; Jaquet *et al.*, 2004; Kaufmann and Romanov, 2008). The models developed are thus specific to each aquifer and not immediately applicable to a karst aquifer.

A third type of model is based on a systemic approach, as initiated by (Mangin, 1984). The karst is considered as a system able to both transform an input (rainfall) into an output (discharge) and evaluate the input-output relation using mathematical functions. The systemic approach yields "black box" models based on deconvolutions, functions or machine learning techniques (Thiery *et al.*, 1983; Karam, 1989; Fleury, 2005; Fleury *et al.*, 2007). Such models offer satisfactory results when approximating overall karst system behavior (Larocque *et al.*, 1998; Labat *et al.*, 1999); furthermore, this approach may be conducted on any aquifer without specific system knowledge. Subsequent to this approach, neural networks have been used for karst modeling by Johannet *et al.* (1994) and Kurtulus and Razack (2007) due to their nonlinear capabilities. The present paper has adopted this particular approach.

2.3.2. Flood forecasting

In the context of real-time flood forecasting, a distinction must be drawn between *simulations*, in which the outflow at time *t* is estimated from rainfall at the same time *t* and earlier, and *forecasts*, for which outflow is computed ahead of time. In general, forecasts are obtained by running simulating models using forecasted rainfall values. In this study context, most models studied are distributed physical models like SHE (Beven *et al.*, 1980; Abbott *et al.*, 1986), TOPMODEL (Beven *et al.*, 1984), TOPKAPI (Liu and Todini, 2002) or TOPODYN (Bartholmes and Todini, 2005; Vincendon *et al.*, 2010), which is a flash flood-dedicated version of TOPMODEL. In France, SCHAPI uses distributed models available on the ATHYS platform (Marchandise, 2007). Global conceptual models, such as GR, have also been used for forecasting purposes (Formigué and Lavabre, 2005; Javelle *et al.*, 2008). These models however do not take into account the karst contribution. Recent conceptual models, developed specifically for karst aquifers, have been introduced (Maréchal *et al.*, 2008).

Since water outflow is due to rainfall, outflow forecasting methodologies require either rainfall forecasts or *ad hoc* assumptions regarding future rain events, such as null or constant rainfall. Cloke and Pappenberger (2009) indicated that many forecasting systems were moving towards the use of climatic forecasts (Numerical Prediction Model), thus coupling a climatic model with a forecasting model (Bartholmes and Todini, 2005). Cloke and Pappenberger (2009) pointed out that a major consideration focuses on improving the Numerical Prediction Model.

In addition, the null or constant rainfall hypothesis is unsatisfactory in the case of the Mediterranean rainfalls studied herein, due to their greater temporal and spatial heterogeneity. For this reason, black box-inspired models provide an effective means of investigation. Following this approach, Toukourou *et al.* (2009) showed that neural networks could be successfully applied to forecasting floods without the availability of rainfall forecasts for a fast, but predominantly non-karst, watershed in the Mediterranean zone.

3. Neural networks for flood forecasting

3.1. State-of-the-art assessment

One alternative to physical models consists of utilizing available data in order to build models by machine learning, which for this study involves neural networks. This step will alleviate computational burdens while freeing model designers from the limitations imposed by physical modeling whenever the physical phenomena are too complex or their parametric estimation too difficult.

Studies on rainfall-runoff identification by neural networks were first carried out by Halff *et al.* (1993) and Johannet *et al.* (1994) using a multilayer perceptron. Many studies have used similar models and compared them with the classical rainfall-runoff model (Hsu *et al.*, 1995; Zealand *et al.*, 1997; Sajikumar and Thandaveswara, 1999; Govindaraju, 2000). The most frequently cited advantage of neural networks in hydrology is their ability to model the complexity of the rainfall-runoff relation thanks to their property of universal approximation (Hornik *et al.*, 1989). According to the authors, neural network models provide at the very least similar results to other models. In addition, they noted that such models are capable of managing missing data and offering real-time training.

In most cases, neural networks are used as black box models, yet Johannet *et al.* (1994) proposed transforming the black box into a transparent box, a step that includes *a priori* knowledge in the model architecture. Johannet *et al.* (2008b) observed hidden neuron outputs as the evolution in physical variables, e.g. an estimation of potential evapotranspiration.

Before 2000, research work was primarily performed using static networks and the backpropagation learning rule (Rumelhart *et al.*, 1986); currently however, several authors have presented the advantages associated with dynamic modeling (Coulibaly *et al.*, 2000a; Chiang *et al.*, 2004) as well as the Levenberg-Marquardt learning rule (Coulibaly *et al.*, 2000b). Hydrological data contain special statistical properties with little resemblance to a normal distribution, i.e. high skewness and heteroscedasticity. Extra care had to be taken when normalizing the input and output datasets, e.g. by choosing a specific transformation to reduce these irregularities (Sudheer *et al.*, 2003). Inputs must also be chosen with precaution: data on rainfall, outflow at previous times and sometimes temperature and evapotranspiration are typically available. Several authors have analyzed the relative importance of inputs using correlations (Coulibaly *et al.*, 2000; Sudheer *et al.*, 2002), while others have posited that the nonlinearity of these relations justifies adding other, less correlated inputs (Dae-II and Young-Oh, 2005).

A major component of this body of work focuses on presenting how neural models are more effective than others (either physical or conceptual) without necessarily investigating in depth the issues surrounding the neural method. Yet the generalization capacity of the neural network is often cited as the main issue. While this has been clearly grasped by Dae-II and Young-Oh (2005), it remains a difficult problem due to: i) the dynamic properties of the rainfall-runoff relation; ii) the specific statistical properties of the outflow and rainfall signals; and iii) the significant level of noise inherent in the data. To overcome these difficulties, regularization methods, such as "early stopping", need to be introduced. The application of early stopping

entails evaluating model quality on the basis of a dataset independent of the calibration set: this "stopping set" serves to prevent overtraining (Coulibaly *et al.*, 2000b).

In several cases, the database is too small to build two sets having the same statistical properties (one for training, the other for stopping and validation); it can thus be observed that stopping specializes the model on the stopping set. Model quality is therefore likely to be unduly optimistic. In order to achieve "early stopping", a third independent set must then be introduced (called the "test set", Kurtulus and Razack, 2007).

Concerning flash floods in particular, forecasting was performed by means of neural networks, radial basis function networks and nearest-neighbors, all within the framework of nonlinear, autoregressive models, which take into account past rainfall measurements and past runoff measurements (Piotrowski *et al.*, 2006). The authors note that "all investigated multilayer perceptron networks perform significantly worse when applied to the test data sets". In Sahoo *et al.* (2006) and Sahoo and Ray (2006), flash floods are forecasted by various methods including neural networks. The reported results are satisfactory, due most likely to the very small size of the basins (2 and 20 km²), which simplifies the rainfall-runoff relation; moreover, results have not been obtained on an independent test set. In Schmitz and Cullmann (2008), the generalization step is assessed on an independent test set, but the most intense event of the database is always included in the training set. The importance of such issues was studied by Toukourou (2009), who employed cross-validation (Dreyfus 2005) in order to select model complexity and variables.

In the present work, we show that a rigorous model design procedure, involving model complexity control, variable selection, regularization and independent testing, leads to satisfactory forecasts. A method is proposed herein that, by capitalizing on the correlation analysis proposed by Mangin (1981) and cross-validation, is less time-consuming than cross-validation applied on its own.

3.2. Universal approximation

The interested reader is referred to Dreyfus (2005) for the fundamentals on neural networks. Only the main properties are presented herein. The multilayer perceptron is a feedforward neural network with one hidden layer of N_c sigmoid neurons and a linear output neuron, as shown in Figure 1. This set-up acts as a universal approximator (Hornik *et al.*, 1989) and is nonlinear relative to both its input and parameters. This model is also parsimonious in comparison with other statistical, nonlinear models (Barron, 1993).

The proposed model is intended, at discrete time kT ($k \in N+$, where T is the sampling period), to forecast or simulate the outflow at time (k + f)T, where f is the forecasting horizon ($f \in N+$).



Figure 1: Rainfall-runoff model using a neural network

By denoting the forecasted outflow value as q(k), the observed outflow (i.e. process output) as $q^{p}(k)$, the rainfall vector as $\mathbf{r}(k)$ and the nonlinear function implemented by a feedforward neural network as g_{NN} , the input-output "neural" model has been designed, based on Nerrand *et al.* (1993), as follows:

(a)
$$q(k) = g_{NN}[q^p(k-1), q^p(k-2), ..., q^p(k-n), r(k), r(k-1), ..., r(k-w+1)]$$

Rainfall information was conveyed to the network as a sliding window of width w, whose optimal value was chosen as described in Section 3.4. The information on past outflows was provided by the outflow for the previous discrete time $q^p(k-1)$. Even though this architecture is static (i.e. if all input variables are constant, then the output is also constant), it still allows simulating a dynamic process by the presence of measured discharge as an input variable. This architecture is thus known as "directed" since the model is being directed by measurements of previous outflows. Nerrand *et al.* (1993) demonstrated that this model was the best predictor of data whose noise is mainly added to the output.

Moreover, introduction of the measured discharge as an input variable at previous times contributes information on the process state to the network (Johannet *et al.*, 2008a).

3.3. Training and generalization

The training procedure entails minimizing an error function, which is usually the least squares error. Several training rules exist, although second-order gradient, steepest-descent methods like the Levenberg-Marquardt algorithm are the most efficient (Zhang *et al.*, 1998).

3.3.1. Levenberg-Marquardt algorithm

In using the training dataset, N input-output couples are presented to the network and enable calculating the error function *J* for each time *k* of the learning set, i.e.:

(b)
$$J^{k}(\boldsymbol{c}) = \frac{1}{2} (q^{p} - q(\boldsymbol{c}))^{2}$$

with **c** corresponding to the matrix of parameters.

Based on the classical second-order gradient, steepest-descent methods, the Levenberg-Marquardt algorithm then calculates parameter increments after each presentation of all examples:

(c)
$$\boldsymbol{c}^{i+1} = \boldsymbol{c}^i - \left[\widetilde{\boldsymbol{H}} \boldsymbol{c}^i + \lambda_{i+1} \boldsymbol{I} \right]^{-1} \nabla \boldsymbol{J} \boldsymbol{c}^i$$

where $\tilde{H}c^i$ is the Hessian approximation of the error function at iteration *i*. The matrix is composed of the first derivative of the *J* function. *I* corresponds to the identity matrix. λ_{i+1} is a parameter introduced to transform $[\tilde{H}c^i + \lambda_{i+1}I]$ into a diagonally dominant matrix at the beginning of training.

3.3.2. Accuracy and generalization

Neural networks are able to approximate any differentiable and continuous function (Hornik *et al.*, 1989). As raised in the state-of-the-art section above however, one major issue with machine learning is overfitting and complexity control. An overly complex model will be highly-fitted with learning data and therefore excessively sensitive to data noise. As a consequence, the model will possess poor generalization capability. In contrast, a low-complexity model will not be able to generate enough of a fit with learning data. This problem is known as the bias-variance dilemma and has been mathematically defined in Geman *et al.* (1992). In sum, training error is not a good estimator of the generalization error, hence the generalization error must be estimated over a set independent of the training procedure.

In this study, we have used several regularization methods to prevent overfitting. Some are referred to as active (examples include early stopping), while other methods are called passive (these include cross-validation (Dreyfus 2005)). Early stopping consists of observing generalization performance on an independent dataset (i.e. the stop set) during the training period and then stopping training when the error increases. This increasing error indicates that the model can no longer generalize to unseen data. Using early stopping implies that three distinct sets must be defined, one for training, one for stopping and one for testing. More specifically, for this study, the Nash criterion (see Equation (e)) has been calculated for the stop set, and training was stopped one iteration before the Nash stop criterion starts to decrease.

3.4. Model selection

3.4.1. Model selection by cross-validation

Model complexity depends on its number of free parameters. For the multilayer perceptron used in the present study, this number is equal to $(w+3)N_c+1^2$. Minimizing complexity thus means minimizing N_c and w. Cross-validation offers a method for simultaneously choosing the appropriate number of hidden neurons N_c and the rainfall sliding window w. The complexity is then selected in order to minimize the squared error function. For each model, the crossvalidation score was calculated as follows.

Using the learning set of K subsets, each subset one at a time was reserved as the *validation set*. Training was then performed K times on K subsets (Dreyfus 2005), with the mean squared error also being calculated K times on each validation set. The validation score could be calculated

² Input variables are: w rainfalls, 1 bias, 1 previous outflow; i.e. w+2 variables correlated with N_c hidden neurons. A total of (w+2) N_c free parameters were thus present in the first layer of the neural network. In the second layer, N_c hidden neurons were present along with 1 bias connected to the output neuron, hence N_c +1 free parameters. The number of free neural model parameters is the sum of both first-and second layer parameters.

afterwards. To assess the model's generalization capability through the use of several criteria, the score was calculated with respect to a given "criterion". The cross-validation score thus equals:

(d)
$$S = \sqrt{\frac{1}{K} \sum_{i=1}^{K} Criterion_i}$$

In this study, *Criterion*, was the Nash or persistence criterion (see Section 3.5) of the forecasted outflow for year *i* of the validation set (extending one complete year):

(e)
$$Nash_i = 1 - \frac{\sum_{k=1}^n (q^p(k) - q(k))^2}{\sum_{k=1}^n (q^p(k) - \overline{q^p})^2}$$

Model complexity was selected by retrieving the configuration that maximized the Nash cross-validation score. For each model, 50 different parameter initializations were performed prior to training.

The cross-validation method therefore selects the best complexity corresponding to the specific training set, with each subset used like during validation. The model is not specialized on a given validation set; it can be noted however that this procedure implies investigating the entire field of possibilities, a step that regrettably is very time consuming.

3.4.2. Rainfall width selection by cross-correlation

Rainfall width represents the rainfall history that influences discharge at discrete time *k*. Mangin (1975) showed that a rainfall-discharge cross-correlogram provides information on basin response to a given rainfall event. By plotting the rainfall-discharge cross-correlation, the linear relation between rainfall and discharge can be observed versus the lag between the two time series. Jenkins & Watts (1968) and Mangin (1975) both determined that when the cross-correlation between two time series is less than 0.2, the series can be considered uncorrelated (in which case the cross-correlation becomes like a white noise). The lag time at which the correlation drops below 0.2 is called the "memory effect" in hydrology (Fig. 2), and this lag corresponds to the rainfall width that can reasonably be applied as a network input variable. From a rigorous standpoint, the 0.2 value needs to be adjusted to the number of time series samples under the hypothesis (for a series less than 30 samples long) of a student distribution. Nevertheless, since the student distribution for the very short series in this research cannot be indicated, the 0.2 threshold is maintained without modification.

The cross-correlation method can only be used for the variable selection and takes into account the linear dependence between both time series, while cross-validation enables choosing the best complexity that also includes the number of hidden neurons and thus considers the nonlinearity implemented by the neural network.

Both selection methods can be used either separately or combined for the input variable selection. Cross-correlation offers a possible initial approach to determine rainfall width, with the aim of diminishing the number of combinatorial experiments; then, cross-validation can accurately adjust the width length. This two-step variable selection process was applied in the present study to the *Lez* karst aquifer.



Figure 2: Example of a rainfall-discharge cross-correlogram

3.5. Forecasting

In considering the model presented in Figure 1, forecasting can be performed over several time horizons. When f=0, the model calculates discharge at time k, using the discharge from time k-1 to k-n, along with a rainfall history from k to k-w+1. This architecture corresponds to a simulation mode (as defined in Section 2.3.2). If f is positive, the model calculates discharge at time k+f using the same input dataset as for the simulation mode, yielding a forecast over an f-day horizon without any rainfall forecasting involved.

In order to evaluate more specifically the model's forecasting performance, a persistence criterion (Kitanidis and Bras, 1980) was introduced to compare the model forecast to a so-called "naive" forecast. This naive value proposes as a forecast at time k+f the same signal as that observed at time k: in other words, the discharge is not varying between k and k+f:

(f)
$$C_p = 1 - \frac{\sum_{k=1}^{s} [q^p(k+f) - q(k+f)]^2}{\sum_{k=1}^{s} [q^p(k+f) - q^p(k)]^2}$$

where s is the number of samples and f the forecasting horizon. For the naive prediction, $q^{p}(k) = q^{p}(k+f)$, which implies that $C_{p}=0$. When the model forecast is better than the naive prediction, C_{p} is positive; if it is lower, C_{p} is negative.

In addition, the naive prediction lies close to the observed signal if the forecasting horizon is short (e.g. see Table 8, in which the Nash criteria for several naive predictions have been reported for various forecasting horizons). In contrast, the naive prediction has no correlation with the observed signal if the forecasted horizon is long. Beating the naive forecast thus becomes an easy task.

Persistence cross-validation scores as well as the Nash cross-validation scores can be calculated; these results in turn enable selecting the model by means of an optimally-adapted criterion.

4. Application to the Lez Basin

4.1. The Lez karst aquifer

The *Lez* spring is the major outlet of the karst aquifer located north of *Montpellier* (see Fig. 3). Other outlets (including *Lirou*, *Restinclières* and *Fleurette*) are seasonal springs, functioning during periods of high flow rates. The boundaries of the *Lez* aquifer are the *Vidourle* River Basin to the north and east, the *Hérault* River Basin to the west, and the presumed southern boundary is the *Montpellier* "fold", an east-west directed thrust fault. In spite of the extensive research devoted to the *Lez* aquifer, the hydrogeological basin (as will be detailed hereafter) is not defined accurately at present, especially for its northern and northeastern boundaries. Nevertheless, its area has been estimated at 380 km² (Thiery *et al.*, 1983).

The karst system was developed in late Jurassic and early Cretaceous limestone, with a thickness of approx. 650 m to 1,100 m (Marjolet and Salado, 1976). The lower limit is marl and marly limestone of the middle Jurassic, while the upper limit is marl and marly limestone of the early Cretaceous. The main karst formation outcrops are situated southwest and northeast of the basin (Fig. 3). Including swallow holes, the recharge area is estimated to encompass 130 km² (Fleury et al., 2008; Dörfliger et al., 2008). Most of the aquifer is thus confined, with several perched aquifers existing above its upper limit: Cretaceous limestone (late Valanginian) constituting the Causse de l'Hortus, late Eocene and late Cretaceous limestone constituting the other perched aquifers. Pyrenean and Oligocene tectonics have led to large faults, in a NE-SW direction, along with folds in the E-W direction. At several points of the basin, these faults join karstified limestone and impermeable formations in leading to border springs (Lirou, Lez). As a consequence, the aquifer has been divided into compartments (Lacas and Avias, 1976; Drogue and Grillot, 1976; Bérard, 1983). Of special attention is the Corconne fault, which divides the basin into western and eastern parts (Fig. 3) and whose exchanges are poorly known. In addition, the Corconne fault could function as both a drain (due to the presence of swallow holes and preferential runoff towards the spring) and a "dam" (as a result of permeable/impermeable contact) (Bérard, 1983). A Messinian salinity crisis (from roughly 5 million years ago) has likely affected the karst structure and its southern part in particular; during this crisis, the Mediterranean Sea, which was partially dried, caused deep karstification in karst systems throughout the surrounding area (Gèze, 1979; Clauzon, 1982; Avias, 1995). For this reason, a connection with the southern part of the Montpellier fold might be possible beneath sea level (Touet, 1987).



Figure 3: Presumed feeder basin of the *Lez* spring and available rain gauges - the black line is the boundary of the presumed hydrogeological basin drawn by Conroux (2007).

The *Lez* spring is tapped in order to provide drinking water for the city of *Montpellier*. In 1982, boreholes were drilled to enable pumping inside the main drain of the spring, which often dried up the spring and emptied part of the aquifer. Nevertheless, in order to maintain minimal outflow at the spring, a Public Utility Decree imposes releasing 160 L/s into the river when the spring is dry. Measured discharges at the *Lez* spring include both pumped and recovered discharges. The measurements are therefore a sum of natural and artificial discharges. Moreover, during the autumn, the *Lez* River experiences high flows, which induce a flood hazard in the city of *Montpellier*. Major events like those occurring in December 2002, December 2003 and September 2005 caused widespread damage by flooding residences and destroying bridges, roads and dykes.

4.2. Lez spring models

Due to its position and use as a potable water source, the *Lez* Basin has been extensively studied and has given rise to a considerable set of available data. However, the complexity of both the basin and its incoming rainfall, along with the artificial discharge, poses a very difficult modeling problem.

Modeling studies first began during the 1970's with rainfall-runoff models (Chemin, 1974; Guilbot, 1975). These early versions corresponded to a former behavior of the system, at a time when 132

pumping was performed in the pool. They do however provide valuable knowledge of these complicated systems. Thiery *et al.* (1983) proposed a 3-reservoir model, which is capable of simulating the water level in the spring pool as well as the overflow discharge. Rainfall and pumping data were processed in order to simulate the drawdown. A linear black box model was proposed by Karam (1989) to forecast the water level in the spring pool at a 5- and 10-day horizon during low-flow periods using piezometric data. Karam (1989) also contributed an interesting discussion relative to delimitation of the supply or feeder basin.

More recently, by proceeding with this system through drain pumping, Conroux (2007) and Dörfliger *et al.* (2008) took into account the relations between: i) water level in the pool, ii) overflow discharge, iii) water table in the boreholes, and iv) pumped discharge, all in order to build a model capable of simulating "natural" outflows at the spring. A "natural" discharge chronicle could thus be produced spanning from 1970 through 2005. Based on this chronicle and in an effort to characterize behavior of the *Lez* basin, Fleury *et al.*, 2008 developed a reservoir model to simulate spring discharge and water level in the main drain. The inputs to this model were a combination of effective rainfall measurements from three rain gauges: *Prades le Lez*, *St Martin de Londres* and *Valflaunès* (Fig. 3). The Nash criterion value of 0.80 was obtained for the discharge simulation, with most errors occurring during flood events.

From a synthesis viewpoint, the *Lez* Basin raises a very difficult modeling issue. On the one hand, the tectonically-disturbed karst aquifer is complex and obviously highly heterogeneous, while on the other, rainfall is highly variable in both time and space and very complicated to forecast. Moreover, the measured discharge is, at least in part, artificial due to tapping the spring. As a last consideration, tapping causes the spring to run dry during the summer, thus preventing any direct outflow measurement.

As a result of these considerations, machine learning inspired by the systemic approach seems to be a well-adapted tool for identifying the behavior of such a nonlinear and partially unknown system.

4.3. Application details

The *Lez* Basin modeling exercise focuses on the most recent period of tapping the spring, after the beginning of pumping in the main drain (1982). The discharge time series for the *Lez* spring and the rainfall measurements on three rain gauges presented in Figure 3 are available daily from 1988 to 2006; these values are distributed as indicated in Table 1. Table 2 lists the altitudes of all three rain gauges and of the *Lez* spring. Distances between rain gauges and the spring are also shown.

As indicated in Section 3.3, the database must be divided into three sets: a training set as complete as possible, a test set to evaluate model performance, and a stop set to apply the early stopping method. This last set is to be composed of cycles that are statistically close to the training set (Toukourou, 2009). For this reason, the stop set is composed of two years, i.e. two complete hydrological cycles, exhibiting nearly the same mean cumulative rainfall and discharge with respect to the total database contents. The test set was chosen so as to contain the leading flood events, i.e. in this case the two most intense events: December 2002 and December 2003 (see Table 3). Model generalization was thus assessed on a significant set. Table 3 lists the major

flood events included in the database, along with their maximum daily discharge, rainfall, cumulative rainfall during the event, and the corresponding rain gauge that recorded the maximum precipitation. It is interesting to note that the maximum rainfall was often recorded by the *St Martin* gauge, which is furthest from the spring (Table 2) yet closer to the basin's primary aquifer. At an hourly sampling rate, the rainfall data are highly heterogeneous: correlations equal 0.6 and 0.4 respectively for the most intense events in December 2002 and December 2003, although the daily samplings as used in this study have provided well-correlated signals (Table 4).

| Set | Number of cycles | Date |
|----------|------------------|---------------------------|
| Training | 10 | 01/09/1988 to 31/08/1993, |
| | | 01/09/1996 to 31/08/2001, |
| | | 01/09/2004 to 31/08/2006 |
| Stop | 2 | 01/09/1993 to 31/08/1995 |
| Test | 2 | 01/09/2002 to 31/08/2004 |

| | Altitude | Distance to the Lez spring |
|-------------------------|----------|----------------------------|
| Lez spring | 65 m | |
| Valflaunès | 133 m | 9.8 km |
| Prades le Lez | 85 m | 800 m |
| Saint Martin de Londres | 194 m | 12 km |

Table 2: Altitudes of the rain gauges and Lez gauge station; distances between rain gauges and Lez spring

| Date | Maximal discharge (m³/s) | Maximal daily rainfall (mm/24h) | Cumulated rainfall (mm) | Corresponding rain gauge | Set |
|----------------|--------------------------------|--|----------------------------|-----------------------------|----------|
| November 1988 | 6,7 | 104 | 208 | St Martin | Training |
| November 1993 | 7,1 | 47 | 227 | St Martin | Stop |
| February 1994 | 6,5 | 95 | 148 | Prades | Stop |
| October 1994 | 10,6 | 205 | 297 | St Martin | Stop |
| November 1994 | 9,4 | 151 | 230 | St Martin | Stop |
| December 1996 | 10,6 | 186 | 110 | St Martin | Training |
| January 1997 | 8,5 | 105 | 170 | St Martin/Prades | Training |
| December 1997 | 11,5 | 117 | 295 | St Martin | Training |
| November 1999 | 6,9 | 88 | 156 | St Martin | Training |
| November 2000 | 7,4 | 87 | 143 | St Martin | Training |
| January 2001 | 9,9 | 88 | 151 | St Martin | Training |
| December 2002 | 15,4 | 161 | 366 | St Martin | Test |
| December 2003 | 12,6 | 149 | 267 | Prades | Test |
| September 2005 | 8,8 | 233 | 284 | Valflaunès | Training |
| January 2006 | 7,9 | 102 | 162 | St Martin | Training |

| Table 3: Major flood events included in the database | | | | |
|--|---------------|----------------------|------------|--|
| | Prades de Lez | St Martin de Londres | Valflaunès | |
| Prades le Lez | 1 | 0.85 | 0.90 | |
| St Martin de Londres | | 1 | 0.87 | |
| Valflaunès | | | 1 | |

 Table 4: Rain gauge cross-correlations. The cross-correlogram was computed for each hydrological cycle (September to August, between 1988 and 2006). The correlations presented correspond to the mean of the primary correlation peaks of each cycle.

The first matter therefore is to evaluate the advantage gained by using just one rain gauge within the neural network, as a means of diminishing complexity and thus increasing the generalization capability. From another standpoint, the linear correlation does not presume any advantage that the nonlinear neural network can derive from the small differences between signals. To proceed with this evaluation, an initial step entailed designing a model for each rain gauge and then comparing results. As a second step, the three rain gauges were applied to the network, with a subsequent discussion of results.

4.3.1. Rainfall-runoff modeling using a single rain gauge

The number N_c of hidden neurons was determined by cross-validation. Alternatively, input selection, namely rainfall width selection, was determined using both cross-correlation and cross-validation.

The various results are reported in Table 5. A first observation to be shared is that due to the architecture (directed mode), these results are excellent. The *Lez* spring was simulated to a high level of accuracy (Fig. 5). The Nash criteria calculated on the test set (covering two complete years, including the intense flood event of December 2003) all exceed 0.95. The number of hidden neurons had always been low, which means that the complexity selection was indeed efficient.

In addition, both input selection methods have produced roughly the same results with no great differences from one rain gauge to the next. Except for *Prades*' model, cross-correlation yielded a less complex network; this method however is based on a linear cross-correlation, whereas neural networks are able to accommodate nonlinearity.

| | Prades le | Lez | St Marti | n de Londres | Valflaun | ès |
|--------------------------------|----------------------|-----------------------|----------------------|-----------------------|----------------------|-----------------------|
| Input selection method | Cross- validation | Cross- correlation | Cross- validation | Cross- correlation | Cross- validation | Cross- correlation |
| Rainfall width w (days) | 8 | 9 | 11 | 9 | 10 | 8 |
| Number of hidden neurons Nc | 3 | 3 | 3 | 3 | 3 | 5 |
| Nash Test | 0,96 | 0,95 | 0,95 | 0,95 | 0,95 | 0,95 |

 Table 5: Architecture and performance of simulation models using each rain gauge one at a time

As suggested in Section 3.4.1, the next step combined these two input selection methods. The cross-correlation analysis was performed, yielding rainfall widths around which cross-validation could be applied by calculating cross-validation scores. If the selected width were to correspond to a border of the tested width, then another trial would be required in order to select the better model in terms of the Nash cross-validation score. The results for the *St Martin* rain gauge are shown in Table 6.

| Rain gauge | Memory effect | Tested width | Selected Width | Nash validatio score | Cross- n | Nash test |
|---------------|------------------|--------------------------------|--------------------|----------------------------|-------------|-----------------------|
| St Martin | 8 days | 8 to 10 days 11 and 12 days | 10 days 11 days | 0.81 0.92 | | (non optimum) 0.95 |

Table 6: Width selection using a combination of cross-validation and cross-correlation methods

It can be noted that the combination of both methods leads to the same architecture as cross-validation on its own. However, combining methods allows choosing the number of hidden

neurons and considerably reduces network design time, as compared to an exhaustive application of the cross-validation method.

4.3.2. Rainfall-runoff modeling using 3 rain gauges

As previously mentioned, the rain gauges are well correlated with a daily sampling rate, yet building a network receiving information from all three rain gauges offers some interesting prospects. Unfortunately, including information stemming from the three rain gauges in the network increases complexity and thus could lead to degrading the generalization. To avoid this drawback, a slightly rearranged network that reduces the number of parameters has been proposed. This revised network includes one more linear neuron for each rain gauge, and this extra neuron can be viewed as an additional hidden layer.

The rainfall width of each rain gauge is thus connected to a single linear hidden neuron, which itself is connected to the classical nonlinear hidden layer (Fig. 4). As an example, a 10-day rainfall width for each of the three rain gauges with four hidden neurons requires 124 parameters with the classical two-layer network (as shown in Fig. 1) and just 46 parameters using the 3-layer network (Fig. 4).



³⁻layers model: 46 parameters

Figure 4: Presentation of the 2-layer and 3-layer networks

Since use of all three rain gauges implies three rainfall widths and in order to reduce model design time, both input selection methods were combined, like in Section 4.3.1. The resulting model complexity is presented in Table 7.

Let's note that the selected rainfall widths for *Prades* and *St Martin* correspond to the upper boundary of tested widths; the largest widths (10 and 11 days) were also tested, though they produced a lower cross-validation score than the 9-day width.

The 3-rain gauge model has led to a similar accuracy as the 1-rain gauge model, with a Nash criterion on the test set equal to 0.95.

| | Prades le Lez | St Martin de Londres | Valflaunès |
|--|---------------|-------------------------|----------------|
| Memory effect | 8 days | 8 days | 7 days |
| Runned width | 8 to 10 days | 8 to 10 days | 7 to 9 days |
| Width giving best cross- validation score | 9 | 9 | 7 |

 Table 7: Complexity selection for the three-rain gauge model

The simulated hydrograph is displayed in Figure 5. Since results are very similar for all three gauges, we have only presented hydrographs from the St Martin model (w=11 and N_c =3) and the 3-gauge model (w as given in Table 7 and N_c =4). Both simulated hydrographs slightly underestimate the December 2002 peak. On the other hand, the December 2003 event is underestimated by the 3-gauge model while it is overestimated by the St Martin model.



Figure 5: Simulated discharges at the *Lez* spring. The bar graph corresponds to measured daily cumulative rainfall at the *St Martin de Londres* station. The black line shows the measured discharge at the *Lez* spring; the orange dotted line on the second graph is the simulated discharge using the three-rain gauge model; the green dotted line on the third graph is the simulated discharge using the *St Martin* model with cross-correlation chosen as the rainfall width selection method.

4.3.3. Forecasting

When forecasting, for each horizon, the model selection using both Nash and the persistence cross-validation score have provided the same complexity for most cases. For other cases, results are very close in terms of model complexity and the values of Nash and persistence criteria on the test set.

Both the one-gauge and three-gauge models were used for this forecasting exercise. For onegauge models, results from the cross-correlation and cross-validation input selection methods are similar. The results listed correspond to the cross-correlation rainfall width selection method. Moreover, the Nash criterion found by the naive forecast is included; this score is very high for the short forecasting horizon (0.9 at *St Martin*) and decreases as the forecasting horizon increases. It should also be mentioned that the Nash and persistence criteria do not systematically evolve in a proportional manner with respect to one another; it is indeed possible to obtain negative persistence for a Nash criterion greater than that of the naive forecast (see Table 8), which depends on the signal shape. The Nash criterion of the naive forecast nevertheless offers an interesting guideline.

| Horizon | 1 day | 2 days | 3 days |
|----------------------------------|-------|--------|--------|
| Naive forecast (measured signal) | 0.85 | 0.67 | 0.53 |
| Prades le Lez | 0.76 | 0.81 | 0.68 |
| St Martin de Londres | 0.90 | 0.81 | 0.70 |
| Valflaunès | 0.76 | 0.78 | 0.68 |
| 3 rain gauges | 0.88 | 0.80 | 0.68 |

 Table 8: Nash criteria for various models and forecasting horizons (models were selected by Nash cross-validation score). The width selection method for the one-gauge model (*Prades, St Martin, Valflaunès*) was cross-correlation. For the three-gauge model, both width selection methods were used in combination.

| Horizon | | 1 day | 2 days | 3 days |
|-------------------|--------|-------|--------|--------|
| Prades le l | _ez | -0.68 | 0.40 | 0.30 |
| St Mar Londres | tin de | 0.33 | 0.39 | 0.33 |
| Valflaunès | | -0.74 | 0.31 | 0.30 |
| 3 rain gau | ges | -0.13 | 0.10 | 0.28 |

Table 9: Persistency criteria for various models and forecasting horizons (models were selected by the persistence cross-validation score). The width selection method for the one-gauge model (*Prades, St Martin, Valflaunès*) was cross-correlation. For the three-gauge model, both width selection methods were combined.

Better results in terms of both Nash and persistence criteria were obtained with the *St Martin* model (*w*, as given in Table 10 and N_c =4) and the three-rain gauge model (*w*, as given in Table 10 and N_c =4). The *St Martin* model probably offered the better one-gauge model by virtue of recording greater quantities of rainfall than the others (also note that it has been placed at a higher elevation, see Table 2). By being the furthest from the *Lez* spring (Table 2), the St Martin rain gauge allows this model to produce the better forecasts (the *St Martin* flood energy arrives after the others at the *Lez* spring). As shown in Tables 8 and 9, these results are excellent when considering that no information regarding future rainfall is available. In examining Tables 5 and 9, which report the performances of the various selected models, it appears that the Nash criterion was roughly constant for the simulation models, while persistency differed for the forecasting models (for the 1-day and 2-day forecasting horizons).

The selected rainfall widths for various forecasting horizons are presented in Table 10. It can be noted that the *St Martin* model for a 3-day forecasting horizon, with a rainfall width of 6 days, was

particularly parsimonious. In fact, the vanishing role of rainfall for such an extended horizon was due to the fact that the network, for a forecast at k+3, was able to glean more significant information from the previous observed outflows than from the previous rainfalls. Even though the forecasting function without a rainfall forecast differs from the simulation, it is still interesting to observe that 6 days in the rainfall window plus 3 days of forecasting horizon provides 9 days, which is the window length selected in the simulation mode for the *St Martin* model (using the linear cross-correlation method, see Table 5). For the three-rain gauge model, this phenomenon did not appear, possibly because of the more complex architecture using three layers of neurons, thus making better use of the nonlinear capabilities of neural models thanks to the cross-validation rainfall selection method.

| Model/Horizon | 1 day | 2 days | 3 days |
|----------------|--------------------|--------------------|--------------------|
| St Martin rain | 14 days | 13 days | 6 days |
| gauge | | | |
| 3 rain gauges | Prades: 8 days | Prades: 9 days | Prades: 8 days |
| | St Martin: 9 days | St Martin: 10 days | St Martin: 8 days |
| | Valflaunès: 7 days | Valflaunès: 8 days | Valflaunès: 8 days |

Table 10: Selected rainfall widths for various forecasting horizons, in combining both width selection methods.

The hydrographs calculated for the 2003 test cycle are shown for both these models as well as for each forecasting horizon (Figs. 6-8). The low-flow period has not been shown since the discharge during this period corresponds to a recovery of the minimum prescribed outflow, i.e. 160 L/s (see Section 4.1).



Figure 6: One-day forecasted discharges at the *Lez* spring. The bar graph corresponds to measured daily cumulative rainfall at the *St Martin de Londres* station. The black line indicates the measured discharge at *Lez* spring; the orange dotted line on the second graph is the forecasted discharge using the three-gauge model (in combining both width selection methods); the green dotted line on the third graph is the forecasted discharge using the *St Martin* model with cross-correlation as the rainfall width selection method.

The three-gauge model overestimates the major flood peaks, as opposed to the *St Martin* model underestimations. For other less intense flood peaks, the forecasted and observed values were very similar and synchronous over time. For the *St Martin* model, the persistency index (Table 9) and the hydrograph both tend to suggest that the model has provided a significant forecast one day ahead of time. For the three-gauge model, the persistency index was negative, even though it was the better model in terms of flood forecasting (good synchronism and extrapolation).



Figure 7: Two-day forecasted discharges at the *Lez* spring. The bar graph corresponds to measured daily cumulative rainfall at the *St Martin de Londres* station. The black line depicts the measured discharge at *Lez* spring; the orange dotted line on the second graph is the forecasted discharge using the three-gauge model; the green dotted line on the third graph is the forecasted discharge using the *St Martin* model with cross-correlation as the rainfall width selection method.

For the two-day forecast, a one-day lag time appears at the major flood peak, demonstrating the one-day anticipation capability. Interestingly, the three-gauge model still yields greater peaks than the *St Martin* model; nevertheless, forecasted outflow at the date of the observed peak revealed less than 30% error. The forecast hydrographs however are still acceptable for moderately-intense floods with an actual anticipation of two days for autumn floods (both models) and a shorter anticipation for spring floods. Considering the persistency criteria (Table 9), it appears that the model offers good anticipation capability, which is remarkable for a model devoid of rainfall forecasts.



Figure 8: Three-day forecasted discharges at the *Lez* spring. The bar graph corresponds to measured daily cumulative rainfall at the *St Martin de Londres* station. The black line reveals the measured discharge at *Lez* spring; the orange dotted line on the second graph is the forecasted discharge using the three-gauge model; the green dotted line on the third graph is the forecasted discharge using the *St Martin* model with cross-correlation as the rainfall width selection method.

Over the three-day horizon, regarding the persistency criteria (Table 9) which are all positive and high, both models would be deemed acceptable; nevertheless, the graphical analysis contradicts this first-level analysis. A one- or two-day lag time appears for all peak floods, yielding an actual anticipation capability of 1 or 2 days, as suggested by the two previous figures. Both models underestimated these peaks, which illustrate the limitations of models without any rainfall forecasts.

4.3.4. Discussion

Regarding the selection method

As underscored in the literature, complexity selection is the major issue in neural network design, given that it determines the generalization capability. Along these lines, cross-validation is a general method that can be used for selecting not only the number of hidden neurons but also the input variables. Unfortunately, this method may be very expensive, from a computational standpoint, due to the combinatorial complexity of the trials to be performed. Concerning determination of the width of the temporal rainfall window application, i.e. the memory effect, we have proposed limiting the field of possible trials by proceeding with two steps: i) preselecting the width around the value provided by the cross-correlation; and ii) adjusting this width accurately in a nonlinear mode (using the neural network) by means of cross-validation.

The proposed method has proven its efficiency in the selection of complexity (i.e. w and N_c), for simulations as well as for forecasting. It can be noticed that the adjustments provided by the cross-validation step to the memory effect were not always in the same direction. Length was reduced for the *Valflaunès* simulation model and increased for the *St Martin* and three-gauge models. These slight differences can be explained by the ability of the neural network to manage the nonlinearity and/or by the fact that the memory effect is not an exact estimation (student
distribution hypothesis). The next section will focus on the quality of models provided by one method versus the other.

Regarding the comparison of input selection methods

A comparison of input selection methods was conducted using the one-gauge model. The simulation results are similar regardless of the rain gauge or input selection method used (Table 5). On the other hand, forecasting results are equivalent in terms of the Nash test criteria, yet not identical. Table 10 shows that the models selected by the combined method vary the rainfall width as a function of forecasting horizon, in particular for the one-gauge model. Moreover, a model selected by cross-correlation alone is unable to adapt to the given forecasting horizon because such a window is predetermined and not allowed to vary. On this application, results have revealed that the performances of both methods were roughly equivalent.

Regarding the simulation mode

The proposed selection method was applied to both one-gauge and three-gauge models. The results provided in simulation mode showed that the three-gauge model was not more efficient than any of the single-gauge models. This finding is consistent with the observation that rain gauges exhibit a high cross-correlation (Table 4) at the daily sampling frequency. At the available time scale, no further information is being provided by the additional rain gauges.

Regarding the forecasting mode

As opposed to the observations in simulation mode, the *St Martin* model yields better forecasts than the other models, and slightly better than the three-gauge model forecasts (Tables 8 and 9), especially for one-day forecasts. This outcome is understandable since the highest rainfall values were mainly recorded by the *St Martin* rain gauge (Table 3). Moreover, this analysis can be refined by examining the hydrographs. For one-day and two-day forecasts, the *St Martin* model underestimated the peaks for principal flood events (December 2002 and December 2003), whereas the three-gauge model overestimated these peaks. The three-gauge model, which overestimated the highest peak of the entire database, while estimating very well the less intense peaks until two days ahead of time, is thus better suited for flood forecasting.

It can also be noted that the rainfall widths (Table 10) narrowed as the forecasting horizon was extended: this behavior is logical since independent of the forecasting horizon, the same rainfall length is required to estimate outflow. This behavior was not observed however for the three-gauge model.

With this as a satisfactory outcome, with a Nash criterion equal to 0.9 (respectively 0.8 and 0.7 for the 1-day and 2-day forecasts), the hydrographs were simulated with good accuracy, primarily due to the network architecture supplied by previous outflows. The ability of neural networks to take advantage of previous outflow observations and not require rainfall forecasts thus offers a very attractive feature.

Lastly, the forecasted hydrographs demonstrate that neural network models are able to extrapolate relative to training data. The highest event in the training set (December 1997) actually reaches a maximum discharge of 11.5 m³/s (Table 3), while the calculated discharge for the

major test set event (December 2002) with a 2-day forecasting horizon ranged between 9 m³/s and 18 m³/s (Fig. 6) when the measured value was 15 m³/s.

5. Conclusion

Forecasting floods in karst and populated basins is a difficult yet critical task. The Lez Basin (in southern France) was chosen as a pilot site to develop and compare forecasting methods for the purpose of setting up an early warning system for the local population. When combining the problems of karst nonlinearity, rainfall unpredictability and an artificial runoff (via pumping for water supply), the Lez Basin has been a preferred study target over the past three decades. In the present paper, we have demonstrated that the systemic approach can be performed by neural networks on the Lez Basin for discharge forecasting until one day ahead of time. The anticipation capability was confirmed until two days ahead of time. Inspired from the memory effect, which is well known within the framework of correlation analysis, an efficient methodology has been proposed to determine neural model complexity. This methodology was then applied to several models based on either a single rain gauge or several gauges. A blind test was conducted on the most intense database event, hence proving that the method, thanks to complexity selection, is able to accurately forecast floods in real time with satisfactory accuracy, in the absence of actual rainfall forecasts. The follow-up to this study will be intended to introduce a priori knowledge on geology and the karst structure. This additional information should constrain the model to physically output interpretable values for its parameters and/or hidden neurons, including for example the relative contributions of various geological zones of this basin.

Acknowledgments

The authors would like to thank the METEO-France weather agency for providing the rainfall datasets, as well as Gilles Le Gac from the DIREN Montpellier Office for contributing discharge data.

We are also very grateful to Caroline Wittwer, Bruno Janet and Arthur Marchandise for the exciting collaboration shared with the SCHAPI Unit, and to Nathalie Dörfliger, Perrine Fleury, Henri Paloc, Daniel Diep, Pierre Roussel-Ragot, Bernard Vayssade and Marc Vinches for the helpful discussions they helped organize.

Lastly, our thanks are extended to Dominique Bertin for his extremely fruitful collaboration in the design and implementation of the Neural Network simulation tool: RnfPro.

References

(Se reporter aux Références bibliographiques en fin de mémoire)

1.2. Éléments clés compris dans l'article

1.2.1. Méthode combinée de sélection des entrées

La méthode de sélection des entrées présentée dans cet article propose d'utiliser les interprétations de la corrélation croisée pluie-débit (Voir chapitre l 2.2.2.1.) pour déterminer la fenêtre temporelle de pluie adéquate pour simuler le débit. Cependant, comme l'analyse corrélatoire croisée ne prend en compte que la corrélation linéaire entre la pluie et le débit, il paraît nécessaire de ne pas se limiter à cette fenêtre. La validation croisée décrite au chapitre II (paragraphe 2.2.2.) intervient alors. Elle permet d'estimer l'erreur de généralisation pour plusieurs fenêtres temporelles, choisies autour de la fenêtre temporelle sélectionnée par l'analyse corrélatoire croisée pluie-débit. Le modèle ayant obtenu le meilleur score de validation croisée (c'est-à-dire ayant la plus petite erreur de généralisation) est retenu.

Dans cette étude, il a été choisi arbitrairement de calculer les scores de validation croisée pour les fenêtres allant de un jour de moins jusqu'à un jour de plus que la fenêtre sélectionnée par corrélation croisée. Comme le montre la Table 6 de l'article, si le meilleur score est obtenu par le modèle qui a la plus grande fenêtre temporelle, le score de validation croisée est calculé pour deux autres modèles comportant un jour et deux jours supplémentaires d'historique de pluie. La même recherche itérative est effectuée si le modèle qui obtient le meilleur score est celui qui a la plus petite fenêtre temporelle.

La combinaison des méthodes de corrélation croisée et de validation croisée permet de mutualiser les avantages de ces deux méthodes :

- Une sélection plus rapide des entrées, sans avoir besoin de tester de nombreuses possibilités comme c'est le cas avec la validation croisée seule.
- La prise en compte de la fonction réelle du réseau, c'est à dire dans notre étude l'estimation des incréments des débits avec un modèle non linéaire, ce qui n'est pas le cas de la corrélation croisée.

1.3. En complément à l'article

1.3.1. Prévision du débit à la source du Lez

L'ensemble de test, indépendant de tous les autres ensembles (apprentissage et arrêt), permettant de valider le modèle, comprend les cycles hydrologiques 2002-2003 et 2003-2004 qui intègrent les deux évènements pluvieux les plus intenses de la base de données (Voir la Table 3 de l'article). Le modèle par réseaux de neurones a effectué avec succès la prévision à un horizon de un jour, puis de deux jours, sans aucune prévision ou hypothèse sur la pluie, ainsi que l'illustrent les Figures 6 et 7 de l'article. Par souci de lisibilité, et comme les interprétations sont très semblables, seul le cycle 2003-2004 a été représenté dans l'article, les résultats pour le cycle 2002-2003 sont donnés ci-après. Les Tableaux 5 et 6 comportent respectivement les critères de Nash et de persistance, en fonction de l'horizon de prévision, pour les modèles utilisant, d'une part le pluviomètre de Saint-Martin-de-Londres, et d'autre part les trois pluviomètres en même

temps (Saint-Martin-de-Londres, Valflaunès, Prades-le-Lez). Les figures Figure 44 à Figure 47 représentent les hydrogrammes mesurés et prévus pour chaque horizon de prévision.

| Horizon | Simulation | 1 jour | 2 jours | 3 jours | |
|----------------------|------------|--------|---------|---------|--|
| St-Martin-de-Londres | 0,92 | 0,80 | 0,73 | 0,66 | |
| 3 pluviomètres | 0,93 | 0,85 | 0,73 | 0,62 | |

Tableau 5 : Critères de Nash pour différents modèles et horizons de prévision.

| Horizon | 1 jour | 2 jours | 3 jours |
|----------------------|--------|---------|---------|
| St-Martin-de-Londres | -0,21 | 0,30 | 0,36 |
| 3 pluviomètres | 0,06 | 0,30 | 0,29 |

Tableau 6 : Critères de persistance pour différents modèles et horizons de prévision.



Figure 44 : Débits simulés à la source du Lez.

Les histogrammes représentent la pluie mesurée à Saint-Martin-de-Londres qui a été utilisée pour la simulation. Les courbes en trait continu sont les débits mesurés, les courbes en tirets sont les débits estimés. Le second graphe correspond au débit simulé en utilisant les pluies de trois pluviomètres (Saint-Martin-de-Londres, Prades-le-Lez et Valflaunès). Le troisième graphe représente le débit simulé en utilisant le pluviomètre de Saint-Martin-de-Londres. Pour les deux simulations, la corrélation croisée a été utilisée comme méthode de sélection des entrées.



Figure 45 : Débits prévus à la source du Lez à un horizon de prévision de un jour.

Les histogrammes représentent la pluie mesurée à Saint-Martin-de-Londres qui a été utilisée pour la prévision. Les courbes en trait continu sont les débits mesurés, les courbes en tirets sont les débits prévus. Le second graphe correspond au débit prévu en utilisant les pluies de trois pluviomètres (Saint-Martin-de-Londres, Prades-le-Lez et Valflaunès). Le troisième graphe représente le débit prévu en utilisant le pluviomètre de Saint-Martin-de-Londres. Pour les deux prévisions, la corrélation croisée a été utilisée comme méthode de sélection des entrées.



Figure 46 : Débits prévus à la source du Lez à un horizon de prévision de deux jours.

Les histogrammes représentent la pluie mesurée à Saint-Martin-de-Londres qui a été utilisée pour la prévision. Les courbes en trait continu sont les débits mesurés, les courbes en tirets sont les débits prévus. Le second graphe correspond au débit prévu en utilisant les pluies de trois pluviomètres (Saint-Martin-de-Londres, Prades-le-Lez et Valflaunès). Le troisième graphe représente le débit prévu en utilisant le pluviomètre de Saint-Martin-de-Londres. Pour les deux prévisions, la corrélation croisée a été utilisée comme méthode de sélection des entrées.



Figure 47 : Débits prévus à la source du Lez à un horizon de prévision de trois jours.

Les histogrammes représentent la pluie mesurée à Saint-Martin-de-Londres qui a été utilisée pour la prévision. Les courbes en trait continu sont les débits mesurés, les courbes en tirets sont les débits prévus. Le second graphe correspond au débit prévu en utilisant les pluies de trois pluviomètres (Saint-Martin-de-Londres, Prades-le-Lez et Valflaunès). Le troisième graphe représente le débit prévu en utilisant le pluviomètre de Saint-Martin-de-Londres. Pour les deux prévisions, la corrélation croisée a été utilisée comme méthode de sélection des entrées.

Les résultats en simulation et en prévision à un jour montrent que le réseau de neurone a été capable d'extrapoler le débit de la crue la plus importante par rapport aux autres évènements à partir desquels le réseau a effectué son apprentissage. En effet, l'évènement le plus intense de l'ensemble d'apprentissage est l'évènement de décembre 1997 qui a un débit maximal de 11,5 m³/s (Voir Table 3 de l'article), alors que l'évènement de décembre 2002 représenté sur les hydrogrammes atteint un débit maximal de 15,2 m³/s et est correctement simulé est prévu à un horizon de un jour.

2. Comparaison de deux approches pour la simulation des débits et de la piézométrie à la source du Lez

La première partie de ce chapitre a démontré l'intérêt de l'apprentissage statistique pour la simulation et la prévision des débits journaliers de la source karstique du Lez. Dans ce paragraphe, il est proposé de mener à bien une comparaison de deux approches systémiques : le réseau de neurones qui fait l'objet de cette étude, ainsi qu'un modèle de type modèle à réservoirs, plus classique en hydrologie, le modèle VENSIM que nous avons évoqué au chapitre III et qui a récemment été développé sur la même source que le modèle neuronal. Les simulations ont été effectuées en collaboration avec l'équipe « Eau » du BRGM (Bureau des Recherches Géologiques et Minières) de Montpellier dans le cadre du projet *Lez Multi-Usages* piloté par le BRGM, et réunissant plusieurs équipes dont le laboratoire HydroSciences Montpellier. Les simulations, ce point est important à noter, ont donc été effectuées par des équipes expertes dans l'utilisation de

chacun des modèles. C'est Perrine Fleury au BRGM qui a effectué toutes les simulations pour le modèle VENSIM.

L'objectif de ces simulations est de comparer, d'une part, le fonctionnement des deux modèles, et d'autre part, leur sensibilité aux variables d'entrée. Pour cela, trois chroniques de pluie sont considérées successivement : la pluie brute, la pluie efficace et la pluie brute à laquelle s'ajoute une donnée « d'évapotranspiraton présupposée » qui se présente sous la forme d'une courbe gaussienne ou sinusoïdale, maximale lorsque l'évapotranspiration est la pluie efficace et une information « qualitative » sur l'évapotranspiration. Pour rendre les simulations comparables pour les deux modèles, les données d'entrée et de sortie, les ensembles de test et de calage/apprentissage sont identiques.

Pour les deux modèles, des améliorations ou de légers changements ont été opérés par rapport à ce qui a été présenté dans les chapitres précédents. Ces changements sont précisés dans la première section. Les résultats concernant la simulation du débit et de la piézométrie de la source du Lez sont présentés dans les deuxième et troisième sections.

2.1. Caractéristiques du modèle neuronal et du modèle à réservoir

2.1.1. Le modèle conceptuel VENSIM

Le modèle choisi est le modèle VENSIM qui a déjà été présenté au chapitre III, paragraphe 3.2.2. Il a cependant été adapté et simplifié pour être plus parcimonieux. Deux nouvelles versions sont présentées dans ce qui suit.

Ces deux nouvelles versions sont proposées ne comportent plus qu'un réservoir, contre trois pour la version initiale du modèle. Le réservoir représente la zone saturée et reprend les caractéristiques du réservoir zone saturée du modèle initial à savoir :

- Un seuil de débordement $h_{débordement}$ pour lequel une fraction $x_{débordement}$ de la pluie est évacuée et sort du système (autres sources non jaugées).
- La hauteur d'eau h_{pompée} calculée à partir des valeurs mesurées du pompage, est soustraite à la hauteur d'eau présente dans le réservoir.
- Le débit sortant *q*_{sortant} est calculé en fonction de la hauteur d'eau présente dans le réservoir comme cela a été présenté au chapitre III.

Cependant deux versions du modèle VENSIM ont été mises en œuvre en fonction du coefficient de tarissement (inverse de la constante de temps du modèle); notons VENSIM 2a et VENSIM 2b, ces deux versions :

Le réservoir du modèle VENSIM 2a comporte deux coefficients de tarissement a₁ et a₂. Un seuil noté H_{1,2} détermine, en fonction de la hauteur d'eau, le coefficient de tarissement à utiliser (Figure 48). a₂<a₁ ce qui signifie que lorsque la hauteur d'eau dans le réservoir est élevée (> H_{1,2}), la vidange se fait plus rapidement que lorsque la hauteur d'eau dans le réservoir est faible.

VENSIM 2a comporte donc cinq paramètres (en rouge sur la figure) auxquels il faut ajouter les deux paramètres permettant la simulation de la piézométrie le cas échéant (voir chapitre III).





r est la pluviométrie mesurée, p est le débit pompé.

Le réservoir du modèle VENSIM 2b est le modèle le plus parcimonieux utilisé dans cette étude. Il ne comporte qu'un seul coefficient de tarissement : α_{ZN}. Ce modèle ne possède donc que trois paramètres pour l'estimation du débit : α_{ZN}, x_{débordement} et h_{débordement} (Figure 49), plus les deux paramètres relatifs à la piézométrie comme pour le modèle VENSIM initial (chapitre III paragraphe 3.2.2.), soit cinq paramètres dans ce dernier cas.





Le calage de ces modèles est effectué visuellement sur les cycles hydrologiques choisis pour le calage (paragraphe 2.1.3 de ce chapitre), il est donc très dépendant de l'opérateur.

2.1.2. Le modèle neuronal

Il s'agit du perceptron multicouche décrit au paragraphe 1. de ce chapitre. Cependant il faut noter une différence majeure avec le réseau utilisé dans l'article inclu au 1. de ce chapitre. En effet, pour 152 pouvoir comparer son fonctionnement avec celui du modèle à réservoir, nous avons choisi de travailler avec les mêmes variables d'entrées pour les deux modèles ; or le modèle VENSIM n'utilise pas le débit observé au jour précédent, mais comme un modèle à réservoir qui suit la loi de Maillet, il utilise le débit estimé au jour d'avant (A. Johannet, 2011). En conséquence le réseau de neurones doit utiliser durant son apprentissage les débits estimés ; il est donc **non-dirigé**. Le modèle ainsi conçu est un modèle récurrent qui peut donc être sujet à des instabilités, phénomène que nous n'avons jamais observé.

Il est important de noter que le choix de l'apprentissage dirige ou non-dirigé est habituellement fondé sur d'autres critères que celui qui a présidé notre présent choix, en particulier la prise en compte des perturbations sur le modèle hypothèse (O. Nerrand *et al.*, 1993). De plus l'apprentissage du réseau récurrent peut être effectué en prenant en compte la dynamique du processus au moyen de la méthode des copies (O. Nerrand *et al.*, 1993). N'ayant pas eu le temps matériellement de mettre en œuvre la méthode des copies, nous considérons que, du point de vue de l'apprentissage statistique, les résultats que nous présentons ne pourront qu'être améliorés en utilisant tous les outils optimaux fournis par la bibliographie.

Le débit restitué de 160 L/s à la source est systématiquement ajouté au débit simulé par le réseau lorsque celui-ci est inférieur à 160 L/s. De plus le débit pompé du jour est également intégré aux variables d'entrée. La figure suivante présente le modèle utilisé dans le cadre de cette comparaison. On note que le modèle de simulation utilise les précipitations du jour k et les débits estimés du jour k-1 pour estimer les débits du jour k. Les débits estimés q(k-1)sont tout simplement ceux qui sont estimés lors du calcul précédent du réseau.



Figure 50 : Perceptron multicouche non dirigé et comprenant le débit pompé en entrée. La complexité du modèle est sélectionnée selon la procédure suivante :

- Pour chaque nouvelle simulation, la largeur de la fenêtre d'historique de pluie (w) et le nombre de neurones cachés (N_c) sont déterminés en prenant le meilleur score de validation croisée, comme cela a été effectué pour le modèle dirigé appliqué à la source du Lez (partie 1. de ce chapitre).
 - Le nombre de neurones cachés est d'abord sélectionné : une fenêtre de pluie de 10 jours fixe est choisie et le nombre de neurones cachés varie de 1 à 5.

Le réseau ayant le plus fort score de Nash en validation croisé permet de choisir le nombre de neurones cachés. Si c'est le réseau à 5 neurones cachés qui est sélectionné, un autre plan d'expérience est nécessaire, faisant varier le nombre de neurones cachés entre 6 et 10.

 Une fois le nombre de neurones cachés fixé, le nombre d'entrées de pluie est choisi de la même manière. Un premier plan d'expérience fait varier les entrées de 1 à 10. Si le meilleur score est obtenu avec 10 entrées, un nouveau plan d'expérience fait varier le nombre d'entrées de 11 à 15. Le meilleur score de Nash permet de sélectionner le réseau final.

Cette procédure est répétée pour 50 initialisations différentes des paramètres du réseau de neurones.

2.1.3. Description des variables

La période considérée va du 01/09/1988 jusqu'au 31/08/2004. Les deux modèles sont testés sur le cycle hydrologique (septembre à août) 2003-2004. Le reste de la période est utilisé pour le calage/apprentissage. Les variables d'entrée du modèle sont les cumuls de pluie journaliers et les débits pompés (du jour k pour simuler le débit du même jour).

Plusieurs chroniques de pluie ont été utilisées :

- r_{pond}. Il s'agit de la pluie pondérée par TEMPO (chapitre III paragraphe 3.2.2.) à partir de six pluviomètres (Pompignan, Prades-le-lez, Saint-Martin-de-Londres, Valflaunès, Montpellier ENSAM et Montarnaud). La pondération obtenue n'en conserve que quatre : 28% Pompignan, 34% Prades-le-lez, 7% Saint-Martin-de-Londres et 30% Valflaunès (Figure 51).
- r_{eff}. Cette chronique correspond à la pluie efficace calculée par le logiciel TEMPO du BRGM
 à partir de la pluie pondérée et de l'évapotranspiration potentielle estimée par Météo
 France à Mauguio, notée e_p.

 $r_{eff}(k) = r_{pond}(k) - e_p(k)$

r_{pond} et évapotranspiration potentielle présupposée. L'évapotranspiration potentielle présupposée (dénommée artificielle ci-dessous) est une courbe gaussienne (pour le réseau de neurones) ou une sinusoïde (pour VENSIM) qui atteint son maximum en été (Figure 52). Cette méthode a déjà été utilisée avec succès pour simuler la relation pluie-débit par les réseaux de neurones par A. Johannet *et al.* (2008b). Pour le modèle VENSIM la variable d'entrée de pluie pondérée vaut alors :

$$r_{pond,etp}(k) = r_{pond}(k) - e_{artificielle}(k)$$

Tandis que pour le modèle neuronal, l'évapotranspiration présupposée est appliquée comme une variable supplémentaire dont il faut également sélectionner la fenêtre temporelle.

Chapitre IV : Modélisation par réseaux de neurones de la relation pluie-débit à la source du Lez



Figure 51 : Pluviomètres et pondération déterminée par TEMPO.



Figure 52 : Evapotranspiration artificielle sinusoïdale et gaussienne normalisées. L' e_{sinus} a été utilisée pour le modèle VENSIM et e_{gauss} a été utilisée avec le modèle neuronal.

Le modèle VENSIM se base sur un bilan hydrologique équilibré (voir chapitre III paragraphe 3.2.2). Pour le calcul de ce bilan, la surface du bassin d'alimentation considérée est de 110 km² lorsque l'évapotranspiration (qu'elle soit estimée ou artificielle) est prise en compte. Lorsque c'est la pluie brute r_{pond} qui est utilisée, aucune information d'évapotranspiration n'est prise en compte, la surface du bassin d'alimentation est alors réduite à 70 km² pour équilibrer le bilan hydrologique.

La figure suivante présente, en trois figures pour plus de lisibilité, les différentes chroniques de pluie et d'évapotranspiration pour l'année hydrologique 2003-2004 qui est utilisée en test pour les modèles. On notera que pour le modèle neuronal, la déduction de la pluie consommée par l'évapotranspiration est effectuée dans la boîte noire et ne peut donc être visualisée en relation avec celle estimée par l'équation précédente.

Au risque de perdre en lisibilité, les trois graphes ont été présentés avec les mêmes échelles afin de faciliter les comparaisons de niveau de précipitation.

Comme indiqué dans le chapitre II, il est nécessaire de normaliser les variables d'entrée et de sortie avant de les introduire dans le réseau de neurones, ceci afin d'avoir des valeurs suffisamment faibles pour ne pas saturer les sigmoïdes. La pluie et le débit et la piézométrie lorsqu'elle est utilisée sont normalisés de façon à avoir une valeur maximale de 0,9. Le débit pompé sont centrés et ramenés à une plage de valeurs allant de -1 à 1.



Figure 53 : Pluie brute, pluie efficace et évapotranspiration potentielle calculée et artificielle.

Les histogrammes présentent la pluie efficace (r_{eff}) et la pluie pondérée (r_{pond}) . Les courbes représentent l'évapotranspiration estimée à Mauguio fournie par Météo-France $(e_p$ Mauguio) et l'évapotranspiration « gauss » artificielle notée egauss.

2.2. Simulation du débit journalier à la source

La simulation du débit a d'abord été effectuée en utilisant comme variable d'entrée r_{pond} , c'est-àdire la pluie brute pondérée afin de prendre en compte plusieurs pluviomètres tout en ayant le moins de variables possible. Cette chronique a l'avantage de ne pas utiliser l'évapotranspiration, qui reste une variable difficile à estimer. On induit ainsi le moins d'erreur possible dans les variables d'entrée des modèles.

Dans un second temps sont utilisées les chroniques de pluie efficace et dans un troisième temps celles de pluie pondérée avec l'évapotranspiration artificielle. Ceci vise d'une part à évaluer les améliorations éventuelles que peut apporter la donnée d'évapotranspiration (estimée ou artificielle), et d'autre part à comparer l'utilisation de l'estimation de l'évapotranspiration réelle avec celle de l'évapotranspiration artificielle. Cette dernière ne nécessitant aucune mesure de terrain (température, vent, ensoleillement...), elle peut être appliquée plus largement que l'évapotranspiration estimée qui a l'avantage d'être plus « physique ».

2.2.1. Variable pluie brute pondérée

Le réseau de neurones prend en compte une fenêtre temporelle de 14 jours de pluie et possède 10 neurones sur sa couche cachée. Il s'agit donc d'un réseau à la complexité particulièrement élevée comparativement aux autres réseaux de neurones pluie-débit que nous avons pu utiliser jusqu'à présent sur la source du Lez. Cette constatation est explicable par le fait que le réseau est récurrent et ne possède pas en entrée le débit observé au jour précédent. Il demande donc plus d'information de précipitation et nécessite une complexité plus élevée. Les dimensions des différents modèles utilisés seront récapitulées et discutées au paragraphe 2.3.4.

Le graphique suivant présente les résultats des simulations effectuées avec VENSIM 2a et le réseau de neurones, prenant tous deux comme variable d'entrée la pluie pondérée. Cette variable est également représentée sur le graphique en histogramme inversé.

Pour la crue principale de décembre 2003, les deux modèles ont un décalage de un jour par rapport au pic de crue observé. Le modèle VENSIM 2a a une amplitude plus proche du débit observé (le pic simulé atteint 97% du pic mesuré) que le modèle par réseau de neurones qui sous-estime la crue (81% du pic observé). Enfin, les crues de printemps sont sous-estimées par les deux modèles.

Les coefficients de Nash sont de 0,75 pour le modèle à réservoir et de 0,79 pour le modèle par réseaux de neurones. On peut remarquer que les valeurs de ces coefficients traduisent assez mal la comparaison entre les deux modèles que nous venons de proposer et qui était plutôt en faveur d'une meilleure modélisation par le modèle VENSIM 2a.





La courbe noire correspond au débit mesuré à la source du Lez, la courbe verte en tirets est l'hydrogramme simulé par le réseau de neurones, et la courbe orange en pointillés est l'hydrogramme simulé par le modèle VENSIM. Les barres inversées représentent le cumul de pluie journalier (pluie pondérée).

Comme les modèles ne reçoivent aucune information concernant l'évapotranspiration potentielle, on peut s'attendre à ce que les débits soient surestimés, en particulier en été. Cependant cette période est très influencée par le pompage qui assèche la source. Le débit mesuré correspond donc au débit restitué. Si les informations de pompage et de débit restitué sont correctement exploitées par les modèles, le débit devrait être correctement simulé sur la période d'été, malgré l'absence d'information sur l'évapotranspiration.

La graphique permet de constater que les données du pompage sont bien prises en compte par les deux modèles. En effet, une pluie au mois de Juin fait réagir les deux modèles mais de façon bien moins importante qu'une pluie similaire survenant au mois de septembre. Il se peut donc que cette réaction soit uniquement due au manque d'information sur l'évapotranspiration.

Pour vérifier cette hypothèse, le calcul suivant propose d'estimer la valeur de l'évapotranspiration qu'il faudrait pour que cette « crue » estimée à tort soit totalement absorbée. Le débit maximal de cette « crue » est d'environ 200 000 m³ et l'aire du bassin d'alimentation de la source est supposée égale à 130 km² (P. Fleury *et al.,* 2008). Toutes les mesures sont converties en mètres :

$$e = \frac{200\ 000}{130.10^6} = 1,5.\ 10^{-3}$$
 Équation 38

Il suffirait donc d'enlever 1,5 mm d'évapotranspiration pour que cette « crue » erronée n'apparaisse plus. A titre de comparaison, à cette période l'évapotranspiration estimée à Mauguio est de l'ordre de 1,5 mm. L'introduction de l'évapotranspiration en entrée des modèles devrait donc permettre d'éviter cette « crue » erronée de la fin du mois de juin.

A la fin de l'été, on constate une différence de comportement pour les deux modèles : le modèle VENSIM 2a ne réagit pas aux pluies du mois d'août alors que le réseau de neurones continue de réagir. Cela pourrait suggérer que le réseau de neurones serait plus sensible à l'absence d'information d'évapotranspiration que VENSIM.

Concernant les périodes pluvieuses, les deux modèles ont un comportement proche sauf pour la première crue d'automne et pour la plus forte crue qui survient au moins de décembre. La première crue d'automne est particulière car le karst est très déprimé à cette époque par le pompage, l'eau doit donc d'abord remplir le réservoir avant que le débit ne réagisse en conséquence. De ce fait, le débit observé forme d'abord un petit pic de crue (< 200 000 m³/jour) avant de passer à une augmentation plus importante (environ 400 000 m³/jour). Ce comportement est mal représenté par VENSIM 2a qui ne réagit pas du tout à la première pluie et atténue fortement le pic suivant. Le modèle par réseaux de neurones réagit de façon plus satisfaisante même s'il surestime le premier pic et sous-estime le second.

L'introduction de la pluie efficace comme variable d'entrée va permettre d'apprécier l'éventuelle amélioration de la simulation, et notamment de vérifier les hypothèses formulées plus haut concernant les réactions indésirables des modèles lors des pluies d'été.

2.2.2. Variable pluie efficace

Les modèles utilisés sont les mêmes que précédemment à savoir VENSIM 2a et le modèle neuronal, mais les calages et apprentissages ont bien entendu été effectués avec la chronique de pluie efficace. De la même façon que précédemment les hydrogrammes sont présentés en Figure 55. La sélection de la complexité du réseau de neurones avec la chronique r_{eff} en entrée a donné un modèle plus parcimonieux que pour la pluie brute : seulement quatre jours de pluie et deux neurones cachés. Les performances sont pourtant équivalentes en termes de critère de Nash qui est égal à 0,78. Ce critère ne traduit pas l'amélioration apportée sur la simulation du pic de crue principal ainsi qu'à l'étiage.

Le pic de crue principal est toujours décalé d'un jour pour les deux modèles, mais l'amplitude est mieux représentée (95% du pic pour VENSIM et 101% pour le réseau de neurones qui estime donc le niveau parfaitement). C'est un point d'amélioration pour le modèle neuronal qui avait une amplitude trop faible dans la simulation précédente. De plus, les crues de printemps sont mieux simulées que précédemment. Sur ce point les deux modèles ont été améliorés. Cependant le modèle VENSIM 2a simule des décrues un peu trop lentes, tandis que pour le modèle neuronal au contraire les décrues sont un peu rapides par rapport au débit observé.



Figure 55 : Hydrogrammes simulés à partir de la pluie efficace calculée par TEMPO sur l'ensemble de test.

La courbe noire correspond au débit mesuré à la source du Lez, la courbe verte en tirets est l'hydrogramme simulé par le réseau de neurones, et la courbe orange en pointillés est l'hydrogramme simulé par le modèle VENSIM. Les barres inversées représentent le cumul de pluie journalier (pluie efficace).

Concernant la période estivale, on constate que les pics de crue du mois d'août ont quasiment disparu, l'évapotranspiration ayant enlevé la plupart des jours de pluie à cette période (voir les histogrammes de pluie sur les Figure 53 et Figure 54) en revanche le pic du mois de Juin est encore présent pour les deux modèles, bien que l'intensité de la pluie correspondante ait été diminuée par l'évapotranspiration. Ceci infirme donc l'hypothèse formulée au paragraphe précédent qui supposait que la prise en compte de l'évapotranspiration permettrait de supprimer le pic de crue indésirable de la fin du mois de Juin. Il reste à vérifier si l'évapotranspiration « artificielle » n'est pas plus efficace dans ce cas, ce qui sera discuté au paragraphe suivant.

Concernant l'automne, de grandes différences apparaissent cette fois entre le modèle par réseaux de neurones et VENSIM 2a. Le réseau de neurones réagit dès la première pluie, confirmant que l'information concernant la vidange du karst n'est pas tout à fait acquise, comme le montrait déjà le paragraphe précédent. Le modèle VENSIM 2a ne réagit pas du tout à la pluie jusqu'au mois de novembre. Ceci est vraisemblablement dû à l'évapotranspiration, trop importante, qui a généré une pluie efficace trop faible pour que le modèle ne réagisse. Encore une fois, l'évapotranspiration artificielle pourra éventuellement apporter une amélioration.

Le coefficient de Nash pour le modèle VENSIM 2a est de 0,55 alors que celui pour le réseau de neurone est de 0,78. La valeur particulièrement basse du coefficient de Nash pour VENSIM 2a est essentiellement due au manque de réaction à l'automne.

2.2.3. Variable pluie brute pondérée et « évapotranspiration artificielle »

Les simulations pour le modèle à réservoir ont cette fois été effectuées avec le modèle VENSIM 2b qui utilise en entrée une chronique de pluie efficace «artificielle» décrite au paragraphe 2.1.3. Le réseau de neurones possède une entrée évapotranspiration (notée ETP par la suite) artificielle distincte de l'entrée de la pluie ce qui lui confère plus de souplesse quant à l'utilisation de l'ETP artificielle. Ces simulations permettront d'évaluer si l'ajout d'une ETP « artificielle », donc disponible pour n'importe quel système hydrologique améliore le résultat comparativement aux simulations faites avec la seule pluie brute pondérée.

Dans un deuxième temps, seront observées les différences entre ces simulations et celles effectuées avec la pluie efficace « réelle », issue de l'estimation de l'évapotranspiration sur le bassin d'alimentation de la source.

Le réseau de neurones a une complexité intermédiaire entre celle obtenue avec la pluie efficace et celle obtenue avec la pluie pondérée, il comporte neuf jours de pluie en entrée et deux neurones sur la couche cachée.



Figure 56 : Hydrogrammes simulés à partir de la pluie pondérée et de l'évapotranspiration artificielle sur l'ensemble de test.

La courbe noire correspond au débit mesuré à la source du Lez, la courbe verte en tirets est l'hydrogramme simulé par le réseau de neurones, et la courbe orange en pointillés est l'hydrogramme simulé par le modèle VENSIM. Les barres inversées représentent le cumul de pluie journalier (pluie pondérée).

Concernant l'étiage, on peut observer que le modèle VENSIM 2b ne réagit plus du tout aux pluies d'été ce qui constitue une amélioration par rapport aux modèles utilisant r_{eff} et r_{pond} . En revanche, le réseau de neurones réagit à chaque pluie, comme pour la simulation avec r_{pond} .

Les épisodes d'automne ne sont pas mieux simulés qu'avec r_{pond} et r_{eff} pour le modèle par réseau de neurones qui donne une simulation très proche de celle qu'il a fournie avec r_{pond} . Le modèle 162

VENSIM 2b réagit un peu plus rapidement à l'automne que le modèle VENSIM 2a, utilisant la r_{eff} mais cette réactions est encore trop tardive puisque le premier grand pic d'automne n'est pas du tout représenté.

Pour le pic le plus important survenu en décembre 2003, on constate toujours un décalage d'un jour pour les deux modèles qui sous-estiment tous deux la crue (seulement 50% du pic est simulé par VENSIM 2b et 81% par le modèle de neurones).

Enfin, concernant les épisodes de printemps, ils sont correctement simulés par VENSIM 2b alors que le modèle par réseaux de neurones sous-estime tous les pics.

L'ajout du signal d'évapotranspiration artificielle n'améliore pas significativement la simulation, comparé aux modèles utilisant la seule pluie brute pondérée. Dans le cas du modèle VEMSIM, cela la dégrade même puisque la première crue d'automne est ignorée et le pic principal de décembre 2003 est particulièrement sous-estimé.

2.2.4. Conclusions sur la simulation pluie-débit

Les tableaux suivants récapitulent les différents critères de Nash et pourcentages du pic simulé pour la crue majeure de 2003 dont nous rappelons que c'est la seconde crue la plus intense de notre base de données; 22 % inférieure au premier événement le plus intense et 9 % supérieure au troisième évènement le plus intense.

| | r _{pond} | r _{eff} | r _{pond} + e _{artificielle} |
|--------|-------------------|------------------|---|
| VENSIM | 0,75 | 0,55 | 0,77 |
| RNF | 0,79 | 0,78 | 0,78 |

Tableau 7 : Coefficients de Nash obtenus pour la simulation du débit journalier à la source du Lez par le modèle VENSIM et par le modèle par réseaux de neurones, en fonction de la chronique de pluie utilisée.

| | r _{pond} | r _{eff} | r _{pond} + e _{artificielle} |
|--------|-------------------|------------------|---|
| VENSIM | 97 % | 95 % | 50 % |
| RNF | 81 % | 101 % | 81 % |

Tableau 8 : Pourcentage du pic principal de débit obtenu pour la crue de décembre 2003 à la source du Lez par le modèle VENSIM et par le modèle par réseaux de neurones, en fonction de la chronique de pluie utilisée.

Ces chiffres, comme les observations notées dans les paragraphes 2.2.1 à 2.2.3, traduisent bien la sensibilité des modèles aux variables d'entrée : le modèle par réseaux de neurones est très peu affecté par les changements de variable d'entrée. Son coefficient de Nash est quasiment constant alors que le pourcentage du pic estimé varie de 20%, avec une excellente simulation pour le modèle utilisant la pluie efficace. Il semble donc que le modèle neuronal ne trouve pas l'information qui lui manque sur l'évapotranspiration quelles que soient les variables proposées. Ceci a l'avantage de fournir un modèle robuste, peu dépendant des données d'entrées. En contrepartie il semble difficile dans ces conditions d'obtenir de meilleures simulations de l'étiage et des premières crues d'automne. Il faut cependant remarquer que ces simulations sont très satisfaisantes, alors même que le modèle par réseaux de neurones a été utilisé en apprentissage non dirigé. On doit noter que ce résultat est tout à fait remarquable pour un modèle récurrent n'utilisant pas le débit précédent observé (rappelons qu'avec le modèle dirigé, le réseau de

neurones effectue une simulation avec un critère de Nash de 0,95 et 87 % du pic retrouvé (paragraphe 1. de ce chapitre)). Par conséquent, le modèle neuronal mis en œuvre apparaît comme un outil fiable, et peu sensible aux variables d'entrées ce qui est très attractif dans un domaine où les données sont souvent très coûteuses. Une fois l'apprentissage effectué, le modèle peut simuler efficacement le débit à la source du Lez en utilisant uniquement la pluie brute.

Concernant le modèle à réservoir VENSIM (2a et 2b), la meilleure simulation est obtenue en utilisant la pluie pondérée. Contrairement au modèle par réseaux de neurones, ce modèle est très sensible aux variables d'entrée, et les chroniques de pluie prenant en compte l'estimation de l'évapotranspiration réelle ont donné de moins bons résultats, tant en termes qualitatif (qualité estimée par simple observation de l'hydrogramme) qu'en termes quantitatifs : le coefficient de Nash est de 0,55 pour le modèle avec la pluie efficace contre 0,77 pour le modèle utilisant la pluie brute. Le modèle prend donc bien compte la donnée d'évapotranspiration mais la façon dont elle est prise en compte n'est peut-être pas assez souple pour fournir de bons résultats, en effet l'ETP est directement retranchée à la pluie avant que celle-ci ne soit donnée en entrée du modèle. Une entrée indépendante d'évapotranspiration qui enlèverait de l'eau au réservoir du modèle VENSIM selon un paramètre à caler serait peut-être préférable, avec l'inconvénient d'avoir un paramètre de plus à caler.

Dans tous les cas, l'information sur le remplissage du karst semble indispensable pour simuler correctement les premières crues d'automne. Au vu des résultats qui viennent d'être présentés, cette information ne peut venir des estimations actuelles de l'évapotranspiration.

En revanche, la piézométrie dans le drain principal pourrait être une information importante pour améliorer l'estimation des crues d'automne, plus pertinente que le débit estimé précédent qui est toujours quasi nul durant l'été. Rappelons que modèle VENSIM a été conçu de manière à simuler soit le débit, soit la piézométrie; il est donc proposé dans le paragraphe suivant de simuler la piézométrie avec les modèles VENSIM et réseaux de neurones.

2.3. Simulation de la piézométrie

L'objectif de ces simulations est d'évaluer la capacité des modèles à représenter l'état de remplissage du karst, ici représenté par la piézométrie. Les variables d'entrées sont les mêmes que précédemment : pluviométrie, débit pompé et éventuellement évapotranspiration. Si les modèles parviennent à faire des simulations correctes de la piézométrie, il sera alors envisageable d'inclure la sortie de ce modèle au modèle de simulation du débit, permettant à ce dernier d'avoir une information sur le remplissage du karst. Dans ce paragraphe, une attention particulière sera donnée à la qualité des simulations lors des premières pluies d'automne, période qui semble la plus problématique d'après les résultats des simulations du débit.

Le signal de piézométrie est très fortement non-linéaire : sa variation est la plus importante en été, lorsque le niveau passe en-dessous de 65 m NGF et s'abaisse à cause du pompage. Au contraire, lors des crues, ses variations sont faibles lorsque le niveau atteint 65 m NGF (voir Figure 57). Pour la piézométrie, les variations les plus fortes sont donc enregistrées en étiage, à l'inverse de la pluviométrie et des mesures de débit. On doit noter que, contrairement à un système

hydrologique classique, la réponse, en termes de variations de hauteur d'eau, est bien plus importante lorsqu'il ne pleut pas (étiage) que lorsqu'il pleut puisque dans ce dernier cas, le débit déborde naturellement par la vasque.

Les simulations de la piézométrie sont effectuées non plus sur un cycle hydrologique mais sur une année civile, afin de représenter au mieux les variations estivales et automnales. L'année de test est l'année 2003. En raison des disponibilités des mesures, les années d'apprentissage seront les années 1997 à 2002.

La démarche suivie est la même que pour l'estimation du débit : en premier lieu c'est la pluie brute pondérée qui est utilisée comme variable d'entrée, puis la pluie efficace calculée grâce à l'ETP estimée à Mauguio et enfin la pluie brute pondérée conjointe à une évapotranspiration artificielle.





La courbe verte correspond à la piézométrie dans le drain principal et la courbe bleue correspond au débit journalier pompé.

2.3.1. Variable pluie pondérée (r_{pond})

Les simulations ont été effectuées avec VENSIM2a et avec le modèle neuronal, en effectuant un nouveau calage/apprentissage de façon à simuler la piézométrie. Le nombre d'entrées et de neurones cachés pour chaque réseau est reporté dans le Tableau 10 et sera discuté par la suite, au 2.3.4.





La piézométrie constante à 65 m NGF est mal représentée par les deux modèles qui continuent de réagir aux pluies de manière exagérée, surtout pour le modèle par réseaux de neurones, qui simule des variations de piézométrie invraisemblables lors de l'épisode pluvieux du mois de décembre. La variation par rapport au niveau 65 m NGF du pic principal par le réseau de neurones et représente plus de 500% de la variation observée (contre 150% pour le modèle VENSIM 2a). Ce problème pourra éventuellement être réglé par l'utilisation de la variable pluie efficace en entrée ou par l'ajout d'une entrée évapotranspiration, au risque de compromettre la qualité du modèle en étiage qui, par ailleurs est très bien simulé par le réseau de neurones.

A l'automne, une brutale remontée du niveau piézométrique est observée lors des premières pluies : le niveau passe de 40 m NGF à 60 m NGF en une seule journée et atteint le niveau de 65 m NGF en seulement deux jours. VENSIM 2a simule bien cette remontée, alors que le réseau de neurones simule une remontée beaucoup plus lente, plus de 30 jours sont nécessaires pour retrouver le niveau de 65 m NGF.

Par contre le modèle VENSIM surestime le déficit de l'été sur le niveau piézométrique : le 8 septembre, VENSIM 2a prévoit un déficit pratiquement deux fois supérieur au déficit observé. Le modèle par réseaux de neurones est meilleur sur ce point, prévoyant en moyenne un déficit égal à celui observé.

Les valeurs des critères de Nash sont de 0,59 pour VENSIM 2a et 0,81 pour le modèle par réseaux de neurones. Le très mauvais critère de Nash pour VENSIM 2a provient de la surestimation du déficit en été.

2.3.2. Variable pluie efficace (r_{eff})

Comme pour l'estimation des débits, l'introduction de la pluie efficace en entrée des modèles a pour objet de leur apporter l'information utile : la pluie qui pénètre dans le système.



Figure 59 : Piézométrie simulée à partir de la pluie efficace sur l'année de test 2003.

La courbe noire correspond à la piézométrie mesurée dans le drain principal de la source du Lez, la courbe verte en tirets est la piézométrie simulée par le réseau de neurones, et la courbe orange en pointillés est celle simulée par le modèle VENSIM 2a. Les barres inversées représentent le cumul de pluie journalier (pluie efficace).

Le modèle VENSIM 2a s'est amélioré sur la première partie de l'hydrogramme, il y est moins sensible aux pluies. En contrepartie, la brutale remontée à l'automne est beaucoup moins bien simulée et le niveau 65 m NGF n'est atteint qu'au mois de décembre. Le rabattement de la nappe en été est également moins bon qu'avec la pluie pondérée.

Le réseau de neurones donne une simulation peu différente de celle effectuée avec la pluie brute pondérée confirmant son insensibilité au type de variable évapotranspiration présenté en entrée. La remontée en automne est plus longue qu'avec la pluie brute, et similaire à celle simulée par VENSIM 2a. Une réaction exagérée est toujours observée au moment de l'épisode de décembre 2003.

L'introduction de la pluie efficace a donc dégradé les résultats, pour le réseau de neurones comme pour VENSIM 2a. Les coefficients de Nash (0,59 pour VENSIM 2a et 0,81 pour le modèle neuronal) sont d'ailleurs les plus bas obtenus de toutes les simulations (voir Tableau 9).

2.3.3. Variables pluie pondérée et évapotranspiration «artificielle »

Sur ces dernières simulations, encore une fois, le réseau de neurones ne donne pas de résultats très différents de ceux présentés précédemment. La simulation produite par le modèle VENSIM 2b a été améliorée, par rapport aux deux autres simulations, pour le rabattement de la nappe en

été, en particulier pour le minima atteint qui se rapproche de la réalité. Cependant la remontée rapide de l'automne, si elle est meilleure que celle effectuée avec r_{eff} , reste moins bonne que celle simulée avec r_{pond} .



Figure 60 : Piézométrie simulée à partir de la pluie pondérée et de l'évapotranspiration artificielle sur l'année de test 2003.

La courbe noire correspond à la piézométrie mesurée dans le drain principal de la source du Lez, la courbe verte en tirets est la piézométrie simulée par le réseau de neurones, et la courbe orange en pointillés est celle simulée par le modèle VENSIM 2b. Les barres inversées représentent le cumul de pluie journalier (pluie pondérée).

2.3.4. Conclusion sur la simulation de la piézométrie

Du fait de sa très forte non linéarité due aux deux types de fonctionnements très différents selon que la source déborde ou est à sec, la simulation de la piézométrie a posé beaucoup plus de difficultés que la simulation du débit. Rappelons qu'une pluie intense, lorsque la source déborde, ne va pas générer une grande hausse du niveau piézométrique, alors qu'en revanche si la source est à sec elle va causer une très grande remontée du niveau de la nappe en début d'automne. Ainsi, pour une même augmentation du niveau piézométrique, il faudra beaucoup plus d'eau si cette variation intervient au-dessus de 65 m NGF par rapport au cas où cette variation intervient en-dessous de 65 m NGF. Pour la même raison, les variations de hauteur sont beaucoup plus importantes pendant l'étiage, c'est-à-dire en **l'absence** de précipitations, lorsque la source ne coule plus et que le pompage se poursuit, faisant ainsi diminuer les réserves. Ces variations se produisent donc à contretemps des variations pluviométriques et on comprend qu'elles posent un problème difficile à un modèle hydrologique.

L'ajout du signal d'évapotranspiration, qu'il soit estimé ou artificiel n'a pas amélioré significativement les simulations, il paraît donc préférable d'utiliser uniquement la pluie brute pondérée en entrée, qui donne de meilleurs résultats, particulièrement à l'automne, pour les deux modèles.

Comme cela a été constaté pour le débit, le modèle neuronal est peu sensible aux variables d'entrée comme l'indiquent les valeurs des critères de Nash présentées dans le Tableau 9. De même, le modèle VENSIM 2 est plus sensible aux variables d'entrées que le modèle neuronal. Par contre il a été en mesure de donner de meilleurs résultats sur deux points : la remontée brutale du niveau piézométrique en automne, et des variations modérées au-dessus de 65 m NGF.

| | r _{pond} | r _{eff} | r _{pond} + e _{artificielle} |
|--------|-------------------|------------------|---|
| VENSIM | 0,70 | 0,59 | 0,80 |
| RNF | 0,85 | 0,81 | 0,86 |

Tableau 9 : Coefficients de Nash obtenus par les deux modèles pour la simulation de la piézométrie, en fonction de la chronique de pluie utilisée.

Le Tableau 10 récapitule les complexités des différents réseaux de neurones utilisés dans cette partie pour la simulation de la relation pluie-piézométrie et de la relation pluie-débit. Dans les deux cas, les réseaux pour l'utilisation de la chronique r_{pond} comportent plus de variables d'entrées, respectivement 12 et 14 pour la piézométrie et le débit, avec un réseau particulièrement complexe (10 neurones cachés) pour la simulation du débit. Les autres réseaux correspondent à des dimensions plus semblables à ce qui avait été constaté pour simuler la relation pluie-débit dans ce travail (article du 1. de ce chapitre): moins de 10 jours d'historique de pluie et entre deux et quatre neurones sur la couche cachée.

| Simulation : | Débit | | | | Piézométrie | |
|---------------------------|-------------------|------------------|--------------------------|-------------------|------------------|--------------------------|
| | r _{pond} | r _{eff} | r _{pond} | r _{pond} | r _{eff} | r _{pond} |
| | | | + <i>e</i> artificielle | | | + <i>e</i> artificielle |
| Nombre d'entrées | 14 | 4 | 9 | 12 | 8 | 6 |
| Nombre de neurones cachés | 10 | 2 | 2 | 1 | 3 | 3 |

Tableau 10 : Dimensionnement des réseaux de neurones pour la simulation de la pluie et de la piézométrie. De plus, on s'attendrait à ce que le nombre de jours nécessaires pour simuler la piézométrie soit supérieur à celui permettant de simuler le débit puisque la piézométrie représente le stockage qui dépend donc de l'infiltration lente. Ce n'est pas ce qui est constaté, sauf dans le cas de l'utilisation de l'ETP artificielle. Ceci est vraisemblablement dû à l'entrée exogène du débit pompé, considérable en amplitude, et par rapport à laquelle l'infiltration retardée doit être minoritaire.

Cette première étude de la simulation de la piézométrie de la vasque du Lez met en lumière la difficulté de la tâche à effectuer avec la simulation de deux comportements contradictoires en fonction de la présence ou non, de débordement à la source. Le fait que le réseau de neurones simule correctement le rabattement de la nappe durant l'été est un point très positif qui permet d'envisager des utilisations complémentaires des deux modèles évalués ; le réseau de neurones simulant la hauteur lorsque la vasque ne déborde pas, et VENSIM prenant la main lorsque celle-ci déborde. Comme il est le plus efficace en étiage, le réseau de neurones peut être utilisé en complément d'un modèle simulant le débit afin d'avoir un modèle efficace sur toute l'année : le modèle de débit pour les périodes où la source déborde et le modèle de piézométrie lorsqu'elle ne déborde pas.

3. Conclusion sur la modélisation de l'hydrosystème du Lez par réseaux de neurones

Dans ce chapitre nous avons appliqué les réseaux de neurones à l'identification de la relation pluie-débit et pluie-piézométrie sur le bassin d'alimentation de la source du Lez. Plusieurs méthodes de sélection des variables d'entrée ont été évaluées. La possibilité de réduire le temps de dimensionnement du réseau a été montrée par l'utilisation conjointe de la corrélation croisée (déjà éprouvée en hydrologie), et de la validation croisée (largement utilisée dans le domaine de l'apprentissage statistique).

Cette première étape a permis de mettre en évidence l'intérêt des modèles neuronaux dirigés pour traiter de la problématique des prévisions de débits d'un bassin karstique complexe. Les coefficients de Nash obtenus sont supérieur à 0,90 en simulation et les prévisions sont très bonnes, voire acceptables jusqu'à un horizon de prévision de un à deux jours pour les débits.

Dans un second temps, la comparaison avec un modèle hydrologique à réservoir nous a permis d'évaluer les performances du modèle neuronal non-dirigé, par rapport à un modèle à réservoir, autre type d'approche systémique plus classique en hydrologie. Cette étape a mis en évidence la robustesse du modèle neuronal dont les résultats ne sont pas dégradés avec l'utilisation de chroniques contenant des incertitudes importantes, notamment sur l'évapotranspiration. Ce dernier point est sans nul doute d'un intérêt majeur dans ce domaine où les mesures sont entachées d'erreur et où les informations climatiques nécessaires pour estimer l'évapotranspiration ne sont pas toujours disponibles. Il faut de plus remarquer que l'ensemble de test a été choisi pour représenter une situation extrême : l'année 2003 a en effet connu et la sécheresse la plus sévère, et l'épisode pluvieux parmi les plus intenses de la base de données dont nous disposions.

Les difficultés de modélisation sur cette période se sont particulièrement fait sentir avec le modèle VENSIM qui présente, par ailleurs, de meilleures performances sur d'autres périodes de test.

La simulation de la piézométrie avec le réseau de neurones a été également abordée dans cette étude; contrairement au comportement du débit qui est intense suite à de grandes précipitations, la piézométrie a des comportements contradictoires : intense baisse quand il ne pleut pas et faibles hausses quand il pleut. Néanmoins, le réseau de neurones a présenté une remarquable réussite à estimer le rabattement de la nappe durant l'été, doublé d'une bonne robustesse par rapport au choix du type de variables utilisées concernant les précipitations (brutes ou efficaces).

Bien entendu, de nombreuses pistes de travaux à effectuer pour l'amélioration de l'estimation de la piézométrie restent à mener, principalement la mise en œuvre de l'apprentissage par copies qui devrait améliorer les performances dynamiques du modèle, de même que la recherche d'une meilleure normalisation de la piézométrie.

D'ores et déjà, nous pouvons remarquer que les deux modèles utilisés : neuronal et à réservoirs présentent des résultats complémentaires pour la simulation de la piézométrie. Ces résultats suggèrent qu'un couplage entre les deux approches : la boîte noire pour les phénomènes

inconnus et le modèle conceptuel pour les phénomènes mieux appréhendés pourrait être un intéressant débouché à cette étude.

Enfin, la qualité des simulations obtenues, y compris sur la simulation des évènements extrêmes de la base de données, tant pour l'estimations des débits en mode dirigé que de la piézométrie en mode non dirigé, laissent à penser que le réseau de neurones a bien été à même d'intégrer dans son fonctionnement le comportement physique du système étudié.

Ce résultat encourageant nous permet donc d'aborder dans la dernière partie de ce mémoire la recherche d'une méthode d'extraction des connaissances apprises par la boîte noire.

Chapitre V : Au-delà de la boîte noire, la méthode KnoX (Knowledge eXtraction) pour l'étude du karst par réseaux de neurones

1. Introduction

Le chapitre IV a permis de démontrer les capacités de l'approche systémique pour la modélisation des systèmes karstiques, et particulièrement pour la modélisation hydrodynamique de l'aquifère karstique du Lez.

Les simulations du débit ou de la piézométrie de la source du Lez effectuées par les modèles neuronaux ont obtenu des résultats excellents y compris sur les événements les plus intenses de la base (crue ou sécheresse), suggérant que ces modèles de type boîte noire sont capables d'intégrer le comportement hydrodynamique du karst.

L'étape suivante, présentée dans ce chapitre a pour objectif d'extraire des connaissances de cette boîte noire sous forme d'informations physiquement interprétables sur le comportement du système karstique. Les modèles neuronaux, jusqu'à présent présentés comme des boîtes noires, seraient alors en mesure de devenir des *boîtes transparentes*, utiles pour la compréhension des systèmes karstiques. Pour cela, la méthode originale proposée est de contraindre le réseau de neurones dans son architecture, à partir d'informations connues *a priori* sur le système. La méthode appliquée dans ce chapitre s'appuie sur les connaissances géologiques disponibles concernant le système karstique du Lez. Le *modèle postulé*, présenté sous forme de schéma-bloc propose d'introduire quatre sous-bassins d'alimentation de la source du Lez. L'architecture particulière du réseau de neurones, suivant ce modèle postulé, est composée de quatre sous-réseaux représentants les sous-bassins d'alimentation de la source. Elle permet d'extraire de ce réseau les contributions au débit de la source et les temps de réponse de chacun des sous-bassins d'alimentation.

Cette étude se compose de trois volets : d'une part la description de la méthode KnoX (Knowledge eXtraction) permettant d'extraire du réseau de neurones des informations physiquement interprétables (contributions de sous-bassins d'alimentation de la source et temps de réponses de ces sous-bassins) et d'autre part une démarche de validation permettant de vérifier le bon fonctionnement de la méthode KnoX. Cette méthode est ensuite appliquée au karst du Lez.

Ce chapitre est rédigé sous la forme d'un article en anglais qui a été soumis à la revue *Water Resources Research*. Pour éviter les redondances concernant les aspects bibliographiques déjà présentés aux chapitres II et III de cette thèse, le lecteur peut se rendre directement au paragraphe 3. de l'article. Le titre et le résumé en français sont donnés ci-après. La méthode KnoX est également décrite, en français, dans un résumé étendu publié dans les actes de la conférence H2Karst qui a eu lieu à Besançon au mois de Septembre 2011. Ce résumé peut être consulté en Annexe C.

2. Utilisation de la géologie pour la modélisation hydrodynamique d'un aquifère karstique par réseaux de neurones. Cas de la source karstique du Lez (Sud de la France)

Résumé :

Comme beaucoup d'aquifères karstiques, le bassin du Lez (Sud de la France) est hétérogène et donc difficile à modéliser. Néanmoins, d'importants enjeux sont associés à la connaissance de son comportement, dus à son exploitation pour l'eau potable et à sa contribution aux crues rapides. Pour répondre à ces questionnements ambitieux, une méthode originale fondée sur les réseaux de neurones est présentée dans le but de mieux comprendre le comportement hydrodynamique d'un tel système. Une architecture particulière est présentée, contenant plusieurs sous-réseaux. Chacun est associé à une zone géologique spécifique, homogène, et correspond à un sous-bassin qui contribue au débit à l'exutoire. Une méthode, initialement proposée pour sélectionner les variables et qui estime la contribution relative de chaque sous-bassin au débit à l'exutoire, a été appliquée pour déterminer à la fois la contribution relative de la zone considérée, et son temps de réponse. Au vu de la difficulté de vérifier ces connaissances qui ne sont pas mesurables, une méthode spécifique de validation est également présentée. Elle consiste tout d'abord à construire un bassin artificiel, modélisant le comportement postulé du bassin réel avec des paramètres entièrement contrôlés (contribution relative et temps de réponse de chaque sous-bassin, au débit artificiel final). Dans un second temps, il a été vérifié que le réseau de neurones est capable d'identifier correctement les contributions et les temps de réponse du bassin artificiel. La méthode a été appliquée avec succès au cas difficile du bassin karstique du Lez. Il faut noter le fait que cette méthode est générique et peut être appliquée à tout bassin dont les données de pluie et de débit sont disponibles.

Use of geological knowledge in the hydrodynamic modeling of a karst aquifer by artificial neural networks: Case study on the Lez karstic spring (southern France)

Line Kong A. Siou^(1,2), Kévin Cros⁽¹⁾, Anne Johannet⁽¹⁾, Valérie Borrell Estupina⁽²⁾, Séverin Pistre⁽²⁾

⁽¹⁾ Ecole des Mines d'Alès, 6 avenue de Clavières, 30319 Alès Cedex, France

⁽²⁾ Université Montpellier II, Hydrosciences Montpellier, Place E. Bataillon,

34095 Montpellier Cedex 5, France

Abstract

As is the case with many karst aquifers, the Lez basin (southern France) is heterogeneous and thus difficult to model. Due to its supply of fresh water and contribution to flash flooding however, more in-depth knowledge of basin behavior proves critical. In addressing this challenging issue, an original methodology based on neural networks is presented herein so as to better understand the hydrodynamic behavior of such systems. A dedicated architecture containing several sub-networks, with each associated to a specific homogeneous geological zone that corresponds to a sub-basin contributing discharge, is described. A methodology, previously proposed for variable selection and capable of estimating the relative contributions of each sub-basin to discharge at the outlet, is applied to determine both the relative contribution of the considered zone and its response time. Given the difficulty of verifying such imprecise knowledge, a specific validation method is also provided. This method comprises two stages: first, building a fictitious basin modeling the targeted behavior of the real basin with fully-controlled parameters (relative contribution and response time of each sub-basin to the final virtual discharge); and second, verifying that the neural network has been able to correctly identify fictitious contributions and response times. This methodology has been successfully applied to the difficult case of the Lez karstic basin, yielding improved knowledge on basin behavior and a delimitation of its feeding basin. It should be emphasized that this methodology is generic and applicable to any basin with available rainfall and discharge data.

1. Introduction

Karst is one of the most widespread aquifer formations in the world, occupying 7% to 10% of all emerged and ice-free landforms on the planet, and providing water for 20% to 25% of the global population [*Ford and Williams*, 2007]. The high level of heterogeneity found in these aquifers however makes them complex with a behavior difficult to forecast. Consequently, the study of karst has become a major concern in the field of water supply management. Moreover, recent studies have concluded the involvement of karst in Mediterranean floods [*Jourde et al.*, 2007;

Bailly-Comte et al., 2008], which are known for their high intensity and potentially catastrophic damage (e.g. the June 2010 event in Var (France) caused 25 fatalities and \in 600 million in direct damage (www.keraunos.org: French Observatory of Tornadoes and Violent Thunderstorms)).

In France, the SCHAPI National Center for Flood Forecasting recently conducted an investigation of karst aquifers. For this purpose, the *Lez* basin was chosen as the pilot, and the present article has been developed around SCHAPI investigation. The research described herein was performed in collaboration with the SCHAPI team and focused on incorporating the specific geological heterogeneity of a karstic basin in order to improve rainfall-runoff modeling.

Since the 1990's, neural networks have been used in hydrology for their capability to identify nonlinear functions [Hsu et al., 1995; Maier and Dandy, 1996]. A rainfall-runoff relationship has been identified by neural network models for many types of basins and has yielded excellent results [Govindaraju, 2000; Maier and Dandy, 2000]. Though these black-box models have proven their efficiency in terms of flood forecasting (see for example [*Campolo et al.*, 1999]), they did not improve the understanding of hydrodynamic processes, geological structures or aquifer storage. Johannet et al. [2008b] and Jain and Kumar [2009] both demonstrated the possibility of building a neural network capable of delivering physically interpretable variables at the output of specific hidden neurons by adding a priori knowledge into the model. Such an approach has been called the "transparent box" [Johannet et al., 2008b]. The present study has adopted this approach and moreover proposes building a geology-based model in order to identify discharge contributions from different geological zones. The contributions of each zone have been calculated using the set of neural network parameters. The calculation method employed was originally proposed to select the most influential input variables and used in this study to extract hidden information from the model. This methodology was then validated virtually, i.e. by means of a fictitious fullycontrolled basin, to confirm that the neural network is able to identify controlled parameters of the fictitious basin.

To begin, the *Lez* Basin will be presented along with its defining aspects, geological considerations and unique mode of operations. The neural network model will be explained next, followed by a description of the knowledge-based box model method that includes its validation on a fictitious basin. Lastly, the results section will present an application of this method to the *Lez* Basin that takes into account its geologic complexity as well.

2. The Lez Basin

The *Lez* is a 28-km long coastal river that crosses the *Montpellier* conurbation (with a 400,000 population) located in southern France. The *Lez* river spring is the major outlet of a karstic aquifer, which is being sustained by a hydrogeological basin estimated to extend nearly 380 km² by *Bérard et al.* [1983]. This section will present the primary findings from studies on the *Lez* Basin, in terms of its geological and structural complexity, as well as the available data and current hydrodynamic knowledge on the aquifer.

2.1. Key findings from studies on the Lez Basin

Proximity to the city of Montpellier and its metropolitan area provides the main rationale for studying the *Lez* aquifer. For starters, the importance surrounding this aquifer relates to water 176

resources: the spring has been operated since the 18th century. Initially, all water withdrawals were gravity-fed, taking advantage of the natural spring flow. During the 1960's, pumps were installed in the spring pool to increase withdrawals from 600 liters/s to 800 liters/s. As Montpellier has expanded, water demand has increased; many studies [*Chemin*, 1974; *Guilbot*, 1975; *Lacas and Avias*, 1976; *Marjolet and Salado*, 1976; *Paloc*, 1979; *Bérard et al.*, 1983] have been carried out as a preliminary step to building and operating boreholes that serve to pump into the main drain upstream of the spring, thus placing greater strain on the largest part of the aquifer. As a consequence, this spring has been under "active water management" since 1982: pumping activity partially empties the aquifer, particularly during the summer season, and the aquifer then fills up during autumn. This practice allows for a 1,700 liters/s withdrawal rate yet often dries up the spring. A public utility decree thus imposed releasing 160 liters/s into the river whenever the spring discharge rate fails to reach 160 liters/s. As a result, the discharge measured at the spring is, at least in part, artificial.

In addition, the climate in this zone is Mediterranean, characterized by intense rainfall events during autumn and capable of delivering tremendous floods known as "Mediterranean episodes". Due to the city's expansion, the *Lez* Basin has become more heavily urbanized, raising concerns over the flood hazard. These Mediterranean episodes are capable of producing catastrophic consequences on human activity and survival. Over the past two decades, over 100 deaths have been recorded in southeastern France, and the event on September 9th, 2002, which occurred on an adjacent non-karstic watershed, caused on its own ϵ 1.2 billion in economic losses [*Gaume and Bouvier*, 2004; *Le Lay and Saulnier*, 2007].

The intensity of these rainfall events, coupled with basin complexity, has complicated flood forecasting efforts (see following section). Recent studies were thus carried out in order to understand karstic basin behavior and improve flood forecasting for the *Lez* River [*Jourde et al.*, 2007; *Bailly-Comte et al.*, 2008; *Fleury et al.*, 2008; *Kong A Siou et al.*, 2011a]. This study has been dedicated to further investigating this particular issue.

2.2. Complexity of the Lez Basin

In this section, the geological and structural organization of the *Lez* Basin will be presented in all its underlying complexity. The current state of hydrodynamic knowledge regarding the aquifer will be discussed at the end of the section.

2.2.1 Lithology and vertical organization of the aquifer

The *Lez* spring basin is mainly composed of Cretaceous and Jurassic carbonate formations, except for its southeastern part, which includes tertiary sandstones and conglomerate (see map in Fig. 1).

The principal aquifer formation includes upper Jurassic and lower Cretaceous limestone, from Argovian to Berriasian stages, leading to thicknesses of 500 to 700 m [*Marjolet and Salado*, 1976]. This formation is limited at the bottom by marl and marly limestone of the Callovian and Oxfordian formation (20- to 150-m thickness) and remains thin and affected by tectonic accidents, allowing the possibility of exchanges between the main aquifer and the middle Jurassic limestone and dolomites of Aalenian to Bathonian formation. These karstified formations, approximately 100 to 450 m thick [*Marjolet and Salado*, 1976; *Bérard*, 1983], are limited at the bottom by the Lias

(Domerian Toarcian and lower Aalenian), yet exchanges between these two aquifer formations are not precisely known. Recently, *Caetano Bicalho* [2010] used both major and trace elements to show that a portion of the water emerging from the *Lez* spring stems from the deep aquifer.

The main aquifer outcrops essentially at the southwestern end of the basin, which thus corresponds to the main direct recharge area. The upper boundary corresponds to lower Valanginien, which outcrops on the eastern and northern sides of the basin, leading to a confined aquifer in these areas. Above this formation lie other carbonate horizons that are also affected by karstification. Three perched aquifers can therefore be distinguished:

- On the northwestern side of the basin, the *Causse de l'Hortus* includes well karstified lower Cretaceous limestone (upper Valanginian), 20 to 150 m thick [*Durand*, 1992]. The *Causse de l'Hortus* is separated from the principal aquifer by marl and marly limestone of the lower Valanginian (100 to 150-m thick). The primary *Causse de l'Hortus* outlet, i.e. the *Lamalou* spring, belongs to the *Hérault* feeding basin; however, several minor outlets can be found in the eastern part of the *Causse*. More specifically, the *Brestalou de Lauret* (river with a permanent spring: *Foux de Lauret*) crosses several sinkholes. Consequently, a proportion of the water infiltrating into the perched *Causse de l'Hortus* aquifer escapes through minor outlets and can then infiltrate once again into the aquifer connected to the *Lez* spring. In addition, spraying campaigns carried out at the *Causse de l'Hortus* have indicated that three types of infiltration were possible (infiltration *via* fractures, *via* secondary fracturation and *via* the matrix), thus generating a lag time relative to the last two types of infiltration, i.e. via the matrix and secondary fracturation [*Durand*, 1992].

- On the northeastern side, lower Cretaceous (Hauterivian) carbonate formation outcrops are composed of limestone and marl; these outcrops are located near the *Corconne* fault, which may favor infiltration and drainage towards the *Lez* aquifer.

- The Upper Eocene (Lutetian) aquifer has developed into lacustrine limestone at the southern end of the basin. On the whole, it is not well karstified, yet some penetrable cavities do exist. Moreover, several intermittent springs are present at the base of this horizon [Durand, 1992], which is least extensive perched aquifer; it outcrops at the southern end of the basin.

Lastly, a discordant Oligocene formation covers the southeastern part of the basin; this formation includes conglomerates and clays and is impervious.

2.2.2 Tectonic setting

The region of interest has been affected by two principal tectonic events. The first corresponds to the Pyrenean compression during Eocene, while the second is the Oligocene distension that opened the Lion Gulf. As a result of these events, the *Lez* aquifer has been affected by two types of tectonic landforms. The first type consists of thrust faults and east-west faults, such as the *Saint Loup* Peak and the "*Montpellier* fold", the latter of which is a faulted anticline with an east-west axis that assumes an impervious limit south of the *Lez* spring. For this reason, it is often considered as the southern boundary of the *Lez* aquifer (see Fig. 2). The second type of landform is composed of sinistral faults with a northeast/southwest direction, such as the *Corconne* fault that crosses the *Lez* Basin (Fig. 1). The *Corconne* fault and its satellites affect the main aquifer and combine pervious and impervious formations. These faults became normal during the Oligocene extension, creating semi-graben to the south of the basin, where impervious tertiary formations 178

outcrop. Furthermore, sinkholes appear along faults, and this serves to increase infiltration and water circulation. In sum, faults play an important role in the hydrodynamics of the *Lez* Basin, whether it be as a drain or a barrier.



Fig. 1: Simplified geological map of the Lez Basin, indicating rain gauges and "geological" zones (Section 3.1.1)

2.3. Assumed hydrodynamic circulations

This section is intended to introduce the current state of knowledge regarding the hydrodynamic behavior of the *Lez* aquifer.

2.3.1. Recharge

Direct karst feeding occurs in free parts of the aquifer, mainly in the southwestern part of the basin. Impervious Toarcian schist also outcrops in this zone, near the *Saint Loup* peak, leading to surface runoff. Sinkholes however exist at the boundaries of this formation and are connected to the *Lez* spring (as revealed by the coloration experiment conducted by CERH-CAF in 1961, as cited by *Karam* [1989]). Areas of more limited aquifers are found to outcrop in the northeastern part of
the basin; moreover, numerous sinkholes are present along the *Corconne* fault and its satellites and these are connected to the *Lez* spring, as indicated by coloration experiments conducted at the *Brestalou de Lauret* sinkhole [*Marjolet and Salado*, 1976] and the *Brestalou de Claret* sinkhole [*Marjolet and Salado*, 1976], along with Paloc 1959 and Guissart 1957, as cited by *Karam* [1989]. As a result, the direct recharge area (aquifer outcrops and sinkholes) was estimated at 130 km² [*Fleury et al.*, 2008].

Infiltration is delayed in perched aquifers, followed by emergence at a spring and then infiltration once again in the main aquifer. This description would apply to infiltration in the *Causse de L'Hortus* aquifer (see previous section), e.g. water infiltrates into the *Causse*, escapes by the *Foux de Lauret* spring and infiltrates once again *via* sinkholes, especially along the *Corconne* fault, as presented above.

2.3.2. Compartments and groundwater circulation

As mentioned above, faults directed northeast/southwest affect the principal aquifer upstream of the *Lez* spring. These faults often create contact between the impervious formation and the aquifer, leading to "dams" in the aquifer. This condition is particularly visible at both the *Lez* and *Lirou* springs, which are "dammed" (Fig. 2). As a consequence, the aquifer is separated into compartments [*Bérard*, 1983].

The *Corconne* fault crosses the basin from northeast to southwest, giving rise to western and eastern compartments; exchanges between the two parts are not accurately known. It is commonly assumed however that in the southern part, water can cross the fault, connecting the southwestern zone (main aquifer outcrops) with the southeastern zone, which includes the *Lez* spring. This crossing is possible since limestone from the principal aquifer is present below Valanginian marly limestone over the eastern part of the basin (Fig. 2). The southwestern part is also drained by the *Lirou* spring, an intermittent spring with a maximum discharge rate of 15 m³/s during flooding [*Karam*, 1989].



Fig. 2: Schematic diagram of the hydrogeological section of the Lez aquifer according to [Fleury, 2008]

Faults may correspond to preferential groundwater circulation paths, particularly in the eastern part of the basin. The *Corconne* fault is a major drain towards the *Lez* spring, as revealed by the coloration experiments [*Drogue*, 1964; *Marjolet and Salado*, 1976; *Bérard*, 1983]. The eastern part of the basin, which is affected by similar faults, would thus be extremely well connected to the spring. This hypothesis was confirmed by studies performed at the *Terrieu* experimental site

[Botton, 1984; Jazayeri Noushabadi, 2009], with a focus on the coloration experiments conducted by Marjolet (1977) and Fabris (1970), as cited by *Karam* [1989] on several sinkholes along the *Terrieu* River. These experiments have highlighted the direct correlation between this zone and the *Lez* spring, since the coloration appears at the spring from 4 to 11 days after injection.

As a final point, the semi-grabens at the southern end of the basin, i.e. downstream of the *Lez* spring and filled by an impervious formation, correspond to a portion of the area of pumping influence [*Bérard*, 1983].



Fig. 3: Assumed hydrodynamic flow, according to [*Bérard* 1983]. The stars correspond to springs while the arrows correspond to groundwater flow

2.4. Availability of measurements

Extensive time series were available as a result of numerous studies conducted on this basin since the 1970's [MEDYCYSS]. In this particular study, six rain gauges were selected by virtue of their location either inside or close to the basin, in assuming an acceptable spatial distribution (Fig. 1). The discharges measured at the *Lez* spring, which is the principal outlet, are available for a long period that includes 12 complete hydrological cycles between 1988and 2004. On the other hand, discharges measured at minor or intermittent outlets, including the *Lirou* spring, *Fleurette, Gour Noir* and *Restinclières* (Fig. 3), were unavailable, due either to a lack of instrumentation or to overly limited time series. The water balance calculation was thus rendered impossible.

The database included daily discharges at the *Lez* spring as well as daily rainfall data from six rain gauges over the 1988-2004 period.

3. Artificial neural network as a knowledge-based box

3.1. "Geological" knowledge input for the neural model

3.1.1. Four "geological" zones

As demonstrated in Section 1, the *Lez* Basin displays considerable geological heterogeneity, and its complex structure determines the organization of groundwater flow. In order to take into account the knowledge presented in the previous section during the modeling process, the basin has been separated into four parts, assumed to be hydrodynamically homogeneous. The main characteristics of these zones will be summarized in this section and in Figure 4.

The southwest zone was identified first and corresponds to the principal outcrop of *Lez* aquifer limestone deposits. It should be noted that another outlet drains this zone during periods of high flow: the *Lirou* spring (see Section 2.3).

The southeast zone corresponds to Tertiary cover and is located downstream of the *Lez* spring. Moreover, the principal aquifer is completely confined in this zone, which has been included in the hydrogeological basin as the area of pumping influence [*Bérard*, 1983].

In the northwest zone, the principal aquifer is mainly confined, except for the outcrop at the extreme northern end of the basin, which corresponds to the *Coutach* massif: this limestone massif is drained partially by the *Sauve* spring and partially by the *Lez* spring. The perched aquifer of the *Causse de l'Hortus* occupies the largest sector of this zone and its primary outlet, the *Lamalou* spring, does not belong to the *Lez* Basin. A number of springs on the eastern side of the massif do however drain a small portion of it [*Durand*, 1992], such as the sustainable spring *Foux de Lauret* that generates the *Brestalou de Lauret*, which then infiltrates (in part) into sinkholes (see Fig. 3). This water therefore joins with the *Lez* aquifer.

Lastly, in the northeast zone, the aquifer remains mainly covered, though many faults would enable infiltration. In addition, due to the orientation of these faults, drainage towards the *Lez* spring becomes possible (2.5).



Fig. 4: Synopsis of the *Lez* basin's hydrodynamic behavior: filled-in squares represent the relative magnitude of the corresponding water course for each zone (black square: major water path; black quarter: minor water path)

3.1.2. Creating a virtual rain gauge for each zone

In order to characterize the hydrodynamic behavior of each geological zone, readings of the rain falling on each zone is a necessary input. For this purpose, the influence areas of all six available rain gauges around the basin were calculated using Thiessen polygons (Fig. 5Fig.). To represent the rain falling on each geological zone, four "virtual" zone rain gauges were created. For each zone, a weighted sum of the nearest rain gauges was derived. The weight for a rain gauge within a zone is proportional to the surface area occupied by the Thiessen polygon of this rain gauge for the targeted zone. As an example, the northwestern zone rain gauge amounted to 72.8% of the Pompignan rain gauge values and 27.2% of the Valflaunès gauge values (Fig. 5).

These four zone rain gauges have thus been made available to establish four rainfall runoff relations.

Fig. 5: Geological zone and rain gauge influence (Thiessen polygons). Percentages indicate the area fraction of the zone belonging to the designated Thiessen polygon. Example: 72.8% of the northeastern zone belongs to the *Pompignan* polygon.

3.2. From the black-box to the knowledge-based box: the "KnoX" (knowledge eXtraction by neural network) methodology

3.2.1. Multilayer perceptron neural network

The fundamentals on neural networks have not been described in depth in this paper; for more specific details, the reader is referred to *Dreyfus* [2005]. In a few words, the multilayer perceptron model was chosen for this study because of its two fundamental properties: universal approximation [*Hornik et al.*, 1989], and parsimony (as regards other nonlinear statistical models [*Barron*, 1993]). The multilayer perceptron is a feedforward neural network composed of one layer of N_c nonlinear hidden neurons and one linear output neuron. Let's set *T* as the sampling period, **w** as a sliding rainfall window width, and $k \in N+$, with both the temporal rainfall window (from time (*k*-**w**+1) to time *k*) and discharge at time (*k*-1) being selected as input variables; also, the discharge at time *k* was adopted as the output data (Fig. 6). In this study, the optimal values of N_c and **w** were chosen, as described in Section 4.3.

Fig. 6: Multilayer perceptron neural network.

The input-output "neural" model was designed on the basis of Nerrand et al. [1993], i.e.:

 $q(k) = g_{NN}[q^{p}(k-1), r(k), r(k-1), ..., r(k-w+1)]$ (1) The simulated outflow value is denoted by q(k), the observed outflow (process output) by $q^{p}(k)$,

the rainfall vector by $\mathbf{r}(k)$, and the nonlinear function implemented by a feedforward neural network by g_{NN} . Such a model is classified as a dynamic, finite impulse response model [Nerrand et al., 1993]; it is renowned for its considerable ability to identify the rainfall-runoff relation and moreover was successfully applied to the Lez Basin [Kong A Siou et al., 2011a]. The dataset was split into several subsets: the training stage consisted of minimizing the mean square error between simulated and observed outflows, on the training set, using the Levenberg-Marquardt algorithm [Hagan and Menhaj, 1994]; both the test set and stop set were determined separately. As it is generally the case in machine learning, it has been shown that due to the bias-variance tradeoff, the generalization step is a major challenge for neural networks [Geman et al, 1992]. In other words, as a result of the nonlinear relations between their various parameters, neural networks are very easily able to identify the desired relation (rainfall-runoff in this case) on the training set. However, training error does not provide a good estimator of generalization error, which more precisely is the error estimated on a dataset never used for training. Furthermore, it has been shown that error increases with the complexity of the neural model, and this complexity is in turn correlated to the number of free parameters in the model. This phenomenon is called overfitting or overtraining; hence, the more complex the neural model, the more sensitive it becomes to overfitting. Special care was thus necessary to adjust model complexity (depending on the number of variables and hidden neurons) in order to capitalize on the generalization properties of neural networks. To proceed along these lines, both variable and complexity selection methods as well as regularization methods need to be employed [Schoups et al., 2008; Toukourou et al., 2009]; their role is to minimize the number of model parameters. This issue has already been analyzed in detail for the Lez Basin in [Kong A Siou et al., 2011a, 2011b]. Models introduced in the present study were optimized using both early stopping and cross-validation. A stop set was used to implement early stopping [Sjöberg et al., 1995]; the cross-validation was proposed by Stone [Stone, 1974] and applied to select both variables (namely, the rainfall windows) and the various hidden neurons [Toukourou et al., 2009]. A test set was also established to assess model quality on training-independent data.

In the following section, several rainfall-runoff relationships will be studied; for each one, a dedicated multilayer perceptron has been implemented and hereafter will be called a *universal approximator*.

3.2.2. An original architecture for building a parsimonious model

Since this study is intended to include geological knowledge into rainfall-runoff modeling, then the rainfall at various places of the basin must be estimated as a function of its localization with respect to the basin's geological structure and recharge rate. Let's denote $R^{g}(\mathbf{w}_{g})$ as the rainfall on the geological zone g. The idea herein is that in an initial "layer" of neurons, applying the rainfall $R^{g}(\mathbf{w}_{g})$ (g=1 to 4) to several universal approximators will enable simulating the unique dynamics of each zone g (g=1 to 4). In a second "layer" of neurons, all contributions from the various zones, namely Z_{g} (g=1 to 4), have been applied to another universal approximator in order to simulate the common part of the dynamics. This knowledge-based network thus constitutes a cascade of several universal approximators.

However, this method increases model complexity by raising the number of parameters to be identified. In order to reduce this number of parameters, the universal approximators placed as input are to be simplified, with each approximator composed of just one linear neuron connected to the rainfall window (see Fig. 7Fig. 7) delivering the contribution Z_g (g=1 to 4). Moreover, to preserve parsimony, each rainfall sliding window length must be adjusted for each of the various geological zones (see Section 3.1.1).

Fig. 7: Parsimonious neural network model for four "geological" zones.

Following the training and in order to extract information from the network, it becomes possible to examine the output of the linear neurons belonging to the first hidden layer or else to calculate the importance of each input so as to evaluate its impact (see Section 4.4).

Naturally, the ability of the neural model to identify separate dynamics for each zone would depend on the differences of both the zone rainfall signals and the zone dynamics.

4. Methodology

4.1. Statistical properties of signals: virtual rain gauges and the Lez outflow

To evaluate the similarity of the four zone rainfall profiles presented above in Section 3.1.2, linear cross-correlations of both rainfall vs. discharge and rainfall from one rain gauge vs. rainfall from the other rain gauges were calculated and will be discussed below.

4.1.1. Linear rainfall-runoff correlation

In an effort to evaluate the correlation between rainfall and discharge, as a function of rainfall location, the linear cross-correlation between *Lez* spring discharges and zone rainfall has been

plotted using each zone's rain gauge for each flood event contained in the database. The maximum value of the linear correlation of rainfall vs. discharge indicates that these two signals were poorly correlated (see Table 1). It is also possible to determine the lag time of the geological zone under consideration by observing the time delay at maximum cross-correlation. These measurements were repeated for 15 intense flood events contained in the database. Due to the major differences observed in results, the median was preferred to the average when estimating the expected maximum cross correlation and time delay.

This linear analysis has shown that discharge tends to be most often correlated with a 2-day delay after a rainfall event (Table 1).

| Zone | Northeast | Northwest | Southeast | Southwest |
|---|-----------|-----------|-----------|-----------|
| Rainfall-discharge cross-correlation | 0.64 | 0.66 | 0.60 | 0.65 |
| Lag time | -2 | -2 | -2 | -2 |

Table 1: Maximum rainfall-discharge correlations and corresponding lag times -

These correlations were calculated using 15 rainfall events (the results presented correspond to median values).

4.1.2. Rainfall-rainfall correlation

| - | Southwest | Northeast | Northwest |
|-----------|-----------|-----------|-----------|
| Southeast | 0.90 | 0.92 | 0.80 |
| Southwest | | 0.93 | 0.89 |
| Northeast | | | 0.92 |

Table 2: Zone rainfall cross-correlation

Along the same lines, the correlations between virtual rainfall amounts were studied. Table 2 shows that zone rainfall is well correlated (at least o.8 in all cases); as a result, it potentially proves difficult for a model (especially a linear model) to differentiate the behavior in these four zones.

The minimum correlation appears between the two southern zones and the northwestern zone, a finding that can be explained by the presence of the greatest relief anywhere in the basin: the *Saint-Loup* Peak located in the northern part of the southwestern zone.

4.2. Data sets for training, stopping and testing

The database comprises 12 hydrological cycles (each hydrological cycle begins on September 1st and ends on August 31st). The database was separated into three sets. First, the test set was composed of just a single cycle, 2002-2003, since this cycle included the most intense rainfall event in the database, allowing it to be used to evaluate the ability of the model to effectively generalize. The stop set should be statistically close to the training set [*Toukourou et al.*, 2009]. The standardized index of daily discharge and rainfall were thus calculated for each cycle. The

1993-94 and 1995-96 cycles wound up being chosen since their index was roughly o. The training set contains the 9 remaining cycles.

4.3. Complexity optimization to retain parsimony

Complexity optimization (for both the variable and hidden neuron number) was conducted in three stages. As suggested in Section 3.1.1, regularization methods were employed: early stopping was applied to all stages and cross-validation, which consumes a considerable amount of calculation time, was only used for the final stage (parameter initialization selection). For all stages, a total of 50 initializations were tested. For starters, the number N_c of neurons on the nonlinear hidden layer was determined (Fig. 7, with N_c varying from 1 to 5) from the same rainfall windows **w** for all four zones. Several experiments were carried out using successively different values of **w** (w = 3 to 9 days). N_c was selected as the number that yielded the best Nash criterion on the test set for the majority of experiments.

During a second stage, the four zone rainfall windows were individually calibrated, with all windows varying over the same time interval. In order to reduce computational complexity, a large window was tested first (from 1 to 10 days) with a large time step (3 days). Next, the windows were refined with a 1-day time step, which corresponded to the sampling period. As was the case previously, results were considered in terms of the Nash criterion calculated over the test set.

The final stage concerned parameter initialization. Fifty initializations were tested once again using the previously-selected architecture, while introducing the cross-validation method. The final initialization thus consisted of selecting the best Nash cross-validation score [Kong A Siou *et al.*, 2011a].

4.4. Extracting hidden information

To perform the variable selection step, *Yacoub and Bennani* [1997] proposed a method for calculating the contribution (*weight*) from each input towards the neural network output (in this case, the simulated discharge). In this paper, for the purpose of highlighting the system's hydrodynamic information, specifically the basin response time, and the relative contribution of each geological zone, this method was applied with an alternative objective.

The weight of each input $r_j(k)$, denoted $P(r_j(k))$, was calculated as follows:

$$P\left(\mathbf{r}_{j}(k)\right) = w_{j} \sum_{n=1}^{N_{c}} (w_{ni} w_{sn})$$
(2)

 $r_j(k)$ is a rainfall input corresponding to the day *j*, *i* the subscript of a linear hidden neuron, *n* the subscript of nonlinear hidden neurons, and *s* the subscript of the output neuron, w_{ij} , w_{sn} and w_{ni} correspond to the different parameter values (Fig. 8) of the neural network after training.

Fig. 8: Parameter notations for the calculation of input contributions

In the proposed model (Section 3.2.2), one input corresponded to one day of rainfall for a predetermined zone. A zone's total contribution was thus computed as the sum of all rainfall contributions (sliding rainfall window) from this zone. For example, suppose the northwestern zone has 10 inputs (rainfall from time *k* to time *k*-9), then its contribution corresponded to $\sum_{i=0}^{9} P(r_i(k))$.

Moreover, in order to estimate a contribution independent of parameter initialization before training, we estimated parameters W_{j} , W_{ni} and W_{sn} as the median of the set of parameters calculated over 50 initializations.

Let's recall (from Section 2.2.) that: i) the water circulation patterns were complicated in at least two superimposed aquifers, and ii) the *Lez* spring is not the sole outlet of the aquifer. The contribution of a specific geological zone to the *Lez* spring discharge is thus difficult to assess.

In this work, we have proposed a methodology based on both a specific neural architecture and an estimation of the contributions of each zone to total discharge, in order to answer the following questions: what is the contribution of each zone to total discharge, and what is the corresponding response time? From this perspective, the methodology provides a means for extracting hidden information from the processes; this methodology will hereafter be referred to as "KnoX" (for Knowledge eXtraction with neural networks).

It should also be pointed out that the contribution of a particular zone to the *Lez* discharge has been estimated without taking into account neuron nonlinearity. Nevertheless, *Yacoub and Bennani* [1997] observed that the estimation of variable importance is indeed rather accurate.

For this last reason, as well as due to the correlation between zone rainfall amounts (which might lead to confusion within the neural network), we have proposed a method devoted to validating the knowledge (i.e. zone contribution and time delay) extracted from the neural model using the aforementioned methodology.

4.5. Validation of the KnoX methodology using a fictitious basin

In order to validate the KnoX methodology explained in the previous section, a fictitious basin has been designed, in correspondence with the presumed conceptual model of the *Lez* aquifer. To achieve this goal, a fictitious discharge has been simulated by a "fictitious *Lez* aquifer" composed of various sub-basins. Given their availability for the real aquifer, the rainfall and discharge data could easily be identified for this fictitious aquifer.

It was then possible to apply the KnoX methodology to this fictitious aquifer: the fictitious signals were applicable to a neural network, designed according to the architecture shown in Figure 7, and knowledge could be extracted from this network.

Next, the extracted hidden information from the neural model could be compared to the fictitious aquifer properties, in terms of contribution and response time of each sub-basin.

4.5.1. Fictitious basin description

Following a presentation of the real aquifer introduced in Section 2.2, the fictitious basin has been composed of four different sub-basins, with each one contributing to the outlet flow of the fictitious basin. It is important to note that the fictitious aquifer model has not been built for realism; instead, its design is intended to produce a behavior similar to that of the *Lez* Basin. The total area of the four fictitious sub-basins was thus established at 100 km². Each fictitious sub-basin has been implemented by a reservoir element; moreover, a reach was computed downstream of each reservoir, whereby each reach introduces a different lag time and loss fraction for each of the sub-basins (Fig. 9). The final fictitious discharge was calculated as the sum of discharges at each reach output.

Fig. 9: Diagram of a fictitious basin

Let's recall that the strong correlation between zone rainfall quantities could serve to introduce errors into the information retrieval stage via the neural model, hence a realistic rainfall pattern must be used to feed the fictitious basin. To this end, for each fictitious sub-basin, actual rainfall data has provided a realistic rainfall profile. The rainfall data from *St-Martin-de-Londres, Valflaunès, Pompignan* and *Montarnaud*, whether near or inside the basin (Fig. 5), have been used. A constant 1 mm/h loss was assumed in order to represent a proportion of the effective rain losses for each sub-basin. Infiltrated water was then introduced to the corresponding sub-basin, with each sub-basin featuring a specific set of loss parameters (let's recall that the *Lez* spring is not the basin's sole outlet; for example, the *Lirou* spring can produce outflows of comparable magnitude as *Lez* during floods). Moreover, the contribution of each sub-basin to the catchment outlet was delayed using various lag parameters.

The fictitious basin was designed using the HEC-HMS software. Details of the corresponding outflow calculation are available in the HEC-HMS Technical Reference Manual [US Army Corps of Engineers, 2000]; only the main steps are provided in this paper. Reservoir outflow was calculated by solving for each time t the following continuity equation approximation: 190

$$\overline{I} - \overline{O} = \frac{\Delta S}{\Delta t} \tag{3}$$

with \overline{I} and \overline{O} denoting respectively the average inflow and average outflow during time interval Δt , and ΔS the storage variation. If $\Delta S = S(t+1) - S(t)$, $\bar{I} = \frac{I(t+1) + I(t)}{2}$ and $\bar{O} = \frac{O(t+1) + O(t)}{2}$ this equation can then be written as follows:

$$\left(\frac{2S_{t+1}}{\Delta t} + \boldsymbol{O}_{t+1}\right) = (\boldsymbol{I}_t + \boldsymbol{I}_{t+1}) + \left(\frac{2S_t}{\Delta t} - \boldsymbol{O}_t\right)$$
(4)

Since the terms on the right-hand side are known, it is possible to calculate $\left(\frac{2S_{t+1}}{\Delta t} + O_{t+1}\right)$ and

obtain the outflow value by using a storage-outflow relationship.

To evaluate the capability of the neural model to accurately identify linear or nonlinear relations, the four reservoirs exhibited storage-outflow functions that could be linear or not.

Reservoir R₁, which corresponds to the S₁ sub-basin, has the following nonlinear storage-outflow function:

$$Q = 10.S$$
 for $Q < 20$ m³/s and $Q = 20$ m³/s for $Q \ge 20$ m³/s (5)
Other reservoirs however revealed a linear storage discharge function:

Q = 10.S

(6) The database has been compiled from previously cited rainfall events occurring between 1988 and 2004. Their outflows were then used to calibrate the fictitious basins.

To validate the KnoX methodology under various scenarios, four experiments were conducted, including various lag times for the sub-basins (Table 4):

- Experiment I: All lag times were the same, and the goal of this experiment was to assess _ whether the neural model was able to identify various contributions for the sub-basins even though these contributions were synchronous.
- Experiment II: The sub-basin (S_3) with the least contribution had a lag time that differed from the others. Was the neural model able to identify the dynamics of this less contributive sub-basin?
- Experiment III: Only the sub-basin contributing a medium amount had a different lag time. As previously indicated, the issue focused on evaluating the capability of the neural model to extract information whenever S_2 and S_3 , i.e. the lowest and highest contributors to final discharge in this case, had identical lag times.
- Experiment IV: S₃ and S₄ display different lag times. The issue then turns to determining whether the neural model was able to identify several distinct lag times (Table 4).

4.5.2. Fictitious "hydrosystem" parameter identification using the neural network model

For each experiment, a neural model (as presented in Section 4.2) was introduced to emulate the behavior of the fictitious basin. The rainfall and discharge of the fictitious basin were actually applied to the neural model. Testing, stopping and training sets were the ones presented in Section 4.2. After training, the contribution and lag time of each zone were calculated and compared to the equivalent data simulated by the fictitious aquifer (Tables 3 and 4) according to

several configurations (Experiments I through IV). The mean contributions of each sub-basin to the fictitious outflow were calculated for all available periods (1988-2004) and provide the reference that is expected to be found by the neural model (Table 3).

| | S ₁ | S ₂ | S ₃ | S ₄ |
|---|----------------|----------------|----------------|----------------|
| Mean contribution to the fictitious discharge | 33.9% | 37% | 8.4% | 19.2% |
| Neural model contributions - I | 33% (3%) | 37% (0%) | 12% (43%) | 17% (11%) |
| Neural model contributions - II | 40% (18%) | 34% (8%) | 9% (7%) | 17% (11%) |
| Neural model contributions - III | 33% (3%) | 43% (16%) | 3% (64%) | 21% (9%) |
| Neural model contributions - IV | 35% (3%) | 35% (5%) | 11% (31%) | 19% (1%) |

Table 1: Mean contribution of each sub-basin to the fictitious aquifer discharge, and neural model contributions -Each of the various experiments (I through IV) implies a different lag time for the reservoirs (see Table 4). Percentages in italics indicate the relative error.

| Sub-basin | S ₁ | S ₂ | S ₃ | S ₄ |
|---------------------------------|------------------------|-----------------------|---------------------|---------------------|
| Rain gauge | Montarnaud | Pompignan | St-Martin | Valflaunès |
| Storage-discharge function | Nonlinear ³ | Linear ⁴ | Linear ^b | Linear ^b |
| Fictitious aquifer - I | 2 days | 2 days | 2 days | 2 days |
| Neural net identification - I | 2 days | 2 days | 2 days | 2 days |
| Fictitious aquifer - II | 2 days | 2 days | 4 days | 2 days |
| Neural net identification - II | 2 days | 2 days | 4 days | 2 days |
| Fictitious aquifer - III | 2 days | 2 days | 2 days | 6 days |
| Neural net identification - III | 2 days | 2 days | 2 days | 6 days |
| Fictitious aquifer - IV | 2 days | 2 days | 4 days | 6 days |
| Neural net identification - IV | 2 days | 2 days | 4 days | 6 days |

Table 4: Lag time for the fictitious aquifer and the lag time identified by the neural model - The contribution to the final discharge differs for each reservoir (see Table 3).

It can first be noted that the contributions were correctly identified for sub-basins S_1 , S_2 and S_4 , which are the most important contributors to discharge. The maximum relative error for their contributions equaled 18% but was often less than 10%. Interestingly, sub-basin S_1 with an associated nonlinear reservoir also exhibited the smallest error. Its contribution to the final discharge was nearly the same as that of S_2 , whose reservoir was linear. On the other hand, the contribution from sub-basin S_3 , which exerted less influence on the final discharge, had an error in excess of 30%, except for the case when this sub-basin had a different lag time from the others (Experiment II: 7% error).

 $^{^{3}}$ See Equation (5).

⁴ See Equation (6).

In conclusion, the fictitious rain gauges and the four experiments made it possible to validate the KnoX methodology for different cases. More specifically, the case of the nonlinear sub-basin S_1 revealed that the neural network was more efficient on this type of nonlinear transformation (it is expected for neural networks to easily identify saturation as a result of their sigmoid function, which has been directly implemented into the network). Results showed that the neural model was able to identify the appropriate solution to fit with the observed data in addition to providing an adequate representation of physical behavior, as regards sub-basin response time. Concerning discharge contributions, results indicate that the maximum error for sub-basins with nonlinear behavior (S_1) was 18%, yet 3% was most often observed. In considering the importance of measurement errors and uncertainty in hydrology (especially in the field of hydrogeology), this uncertainty was acceptable in approximating the contributions of an actual hydrosystem and in proposing hypotheses about predominant groundwater circulation. The following section will present the results obtained on the actual *Lez* basin.

5. Results on the Lez Basin

5.1. Rainfall-runoff modeling

In order to apply the KnoX methodology, a neural model of the aquifer must be designed first. The following architecture, which includes the four zones, was therefore designed according to the recommendations of Section 4.3 (i.e. width of the rainfall window, number of hidden neurons):

| Input variables | | | | | Hidden laver |
|-----------------|-----------|-----------|-----------|----------------------------------|--------------|
| Northeast | Northwest | Southwest | Southeast | Observed discharge | |
| 12 days | 10 days | 8 days | 1 day | 1 day (with a 1-day lag time) | 4 |

Table 5: Neural network architecture with 4 zones for the Lez Basin

It can be noted that the northern zones, including the parts furthest from the *Lez* spring, accounted for a larger rainfall width than southern zones.

Figure 10 presents the estimated hydrograph for test period 2002-2003. The simulation results were very accurate, even for the particularly intense event of December 2002. The Nash criterion equaled 0.96. Since the model produced very satisfactory results, it was possible to pursue the methodology by extracting hidden information.

Figure 10: Observed and estimated hydrographs for the *Lez* spring - The green dotted line reflects the calculated discharge; the black solid line is the measured discharge. The bar corresponds to rainfall in the northeastern zone.

5.2. Extracting information from the knowledge-based box

The contributions of input variables (i.e. zones and past observed discharges) were calculated as explained in Section 4.4. Let's point out that since the neural network minimized the mean square error function during training, the neural network model turns out to be more sensitive to high outflow values. Consequently, it can be assumed that the extracted information has mainly corresponded to the high-flow behavior of the aquifer.

In this section, input contributions are presented as a percentage, thereby reflecting the discharge proportion explained by each input. 88% of all discharge has been explained by the overall rainfall data, and the remaining 12% by past observed discharges (Section 3.2.1), which are used to provide state information to the network. These proportions confirm that the model is mainly capable of identifying the rainfall-discharge relation, to a much greater extent than a discharge-discharge relation.

The details of rainfall contributions are presented in Figure 11, while Table 6 provides additional information regarding surface areas and lag times. It can be observed that if the basin was to be drained by a single outlet with precisely known boundaries, the contribution of each zone should be related to the surface area of each zone. This outcome has not been verified however because of the existence of several outlets; the *Lez* spring is the only gauged outlet in the basin for the duration of the database.

Fig. 11: Calculated contribution of each geological zone for the *Lez* spring discharge

| | | Area (km²) | Area (% of total Area) | Calculated contribution to the <i>Lez</i> spring | Calculated lag time |
|---|-----------|------------|---------------------------|--|------------------------|
| - | Northeast | 147.3 | 36% | 44% | 1 day |
| | Northwest | 87.9 | 22% | 28% | 1 to 3 days |
| | Southeast | 95.9 | 24% | 5% | o day |
| | Southwest | 74.7 | 18% | 11% | 1 day |
| | | | | | |

Table 6: Area, lag time and contribution of each geological zone

Let's start by noting that the southwestern zone has a limited contribution despite being the largest aquifer outcrop, an observation that suggests a significant proportion of the water falling onto this zone does not arrive at the *Lez* spring. This finding can be explained by the existence of the *Lirou* spring, which also drains this part of the aquifer, especially during flooding.

As expected, the southeastern zone shows a limited weight, which can be explained by its location downstream of the spring and by the impermeable cover above the aquifer that prevents infiltration from entering the main aquifer.

The northwestern zone is the second largest, yet the main aquifer outcrop remains limited within this zone, which confirms the significance of surface runoff and concentrated infiltration via sinkholes. In addition, the infiltrated water on of the *Causse de l'Hortus* may emerge at the eastern boundary of the *Causse* and stream and infiltrate into sinkholes. Consequently, this water will arrive later at the *Lez* spring. This section will focus on such considerations with respect to basin response times.

Lastly, rainfall from the northeastern zone accounts for the largest share of spring discharge. Once again, the main aquifer outcrops are limited yet lie very close to faults oriented in the direction of the spring. These numerous faults facilitate drainage and infiltration by sinkholes, as explained in Section 2.3.

5.3. Basin response time

The second step of this analysis consists of observing the contributions vs. lag time. For a given zone, the contributions of each input, namely each day, were calculated, thus making it possible to identify which rainfall day was the most influential and, in this manner, approximating the zone response time. This step was conducted on all geological zones, except for the southeastern zone since its rainfall width extended just one day (Table 5). Figure 12 shows the variation in contributions vs. lag time. Except for the southeastern zone, which responds immediately, the first day of rainfall after the present day k was assigned a predominant weight, thus indicating a short response time of 1 day or less (given that the data are sampled daily). The weights of the northwestern zone remained high up until 3 days, which suggests a longer response duration. Another argument favoring infiltration in *Causse de l'Hortus* was the emergence and delayed infiltration in the *Lez* aquifer by sinkholes.

Fig. 12: Day 0 corresponds to the day of simulation; day -1 is the previous day and so on.

5.4. Role of the southeastern zone

It is worthwhile to discuss the role of the southeastern zone, which appears to contribute little if anything to the *Lez* spring outflow (5% contribution, see Table 6). One can observe that when the response time of the zones differs, like in Experiment II, the accuracy of knowledge retrieval was indeed good (7% error, see Table 4).

When considering the southeastern zone, its response time was retrieved differently from all the others, leading to the supposition of high estimation accuracy, hence the contribution from this basin was extremely small. In an initial approach, it would be logical to remove this zone from the feeding basin. However, according to the analysis by *Bérard* [1983], this zone needs to be included in the feeding basin of the spring though it lies downstream of the spring and is covered by an impervious formation (Section 2.5). Nevertheless, *Bérard* [1983] underscored the connection of the *Lez* spring with the southeastern zone thanks to pumping, by not assuming natural rainfall

infiltration within this zone. Considering the natural rainfall-runoff relation, this zone thus appears to be excluded from the *Lez* spring feeding basin even though the underground portion of this zone belongs to the aquifer influenced by spring pumping.

In order to validate this hypothesis, another experiment was conducted: an extra zone, fed by random rainfall (more precisely, random rainfall was generated when just one real rain gauge was receiving rainfall), was added to the neural model. The idea here was to observe whether the neural model contributed to this zone to a greater extent than the contribution of the southeastern zone. After extracting information, it appeared that the contribution of the extra random rainfall zone was very narrow: only 0.1%. It can thus be concluded that when the considered zone rainfall is weakly correlated with other zones and moreover when this zone has no common behavior with outflow, then the neural model has been able to provide the proof.

Nevertheless, this last experiment did not prove that the southeastern zone belongs to the feeding basin (5% contribution did exceed 0.1%) due to the possibility of inaccuracy resulting from the high correlation of zone rainfall (greater than 0.80 for the southeastern zone, see Table 2).

Lastly, it can be considered that the estimated contribution of the southeastern zone is mainly due to the correlation between zone rainfalls. The neural network, which indicates a very small contribution, guided us towards a new interpretation of *Lez* feeding basin behavior: the southeastern zone must be removed from the basin, and rainfall falling on this zone does not contribute to the water balance of the spring. In addition, the underground portion of the southeastern zone is connected to the spring when pumping is underway. We would like to underscore the importance of this topic being addressed through the modeling of a neural network.

6. Conclusion

Studying karst aquifers is of major interest in water supply management like in flood forecasting. The Lez Basin is a karstic and highly-urbanized basin that showcases these concerns. Operation of the main karstic outlet, in association with the high level of geological complexity, poses a difficult modeling problem. In the present study, a rainfall-discharge neural network model has been developed to represent the basin's geological heterogeneity. Four geological zones were distinguished, and rainfall measurements in each zone were introduced as a separate input into the model. This neural network model architecture has enabled estimating the relative contributions and response times of several sub-basins by calculating the contributions of each input. This methodology was validated using a fictitious hydrosystem that provided fictitious rainfall-discharge relations for four fictitious sub-basins. The neural network model was easily able to correctly identify contributions and lag times of the corresponding sub-basins. When applied to the Lez Basin, the methodology successfully estimated the contributions of each geological zone. Non-proportionality between relative contributions and zone areas indicated the existence of other outlets. Furthermore, the response time of each zone was evaluated, in highlighting the delayed infiltration of the principal aquifer, most likely due to the existence of a perched aquifer. In conclusion, the KnoX methodology introduced in this paper has yielded satisfactory and very interesting results, allowing for further refinements on knowledge of the Lez Basin behavior and for an in-depth examination of basin boundaries.

Acknowledgments

The authors would like to thank the METEO-France weather agency for providing the rainfall datasets, as well as Gilles LeGac from the DIREN's Montpellier Office for contributing the discharge data. We are also very grateful to Caroline Wittwer, Bruno Janet and Arthur Marchandise for the stimulating exciting collaboration shared with the SCHAPI Unit, and to Nathalie Dörfliger, Perrine Fleury, Henri Paloc, Daniel Diep, Pierre Roussel-Ragot, Bernard Vayssade and Marc Vinches for the very helpful discussions they helped organize. Lastly, our thanks are extended to Dominique Bertin for his extremely fruitful collaboration with in the design and implementation of the Neural Network simulation tool: RnfPro.

References

(Se reporter aux Références bibliographiques en fin de mémoire)

3. Conclusion sur l'étude du karst par réseaux de neurones

Dans ce chapitre, une méthode permettant d'extraire du modèle neuronal des connaissances physiquement interprétables sur le système étudié a été proposée. Les connaissances accessibles par cette méthode, appelée KnoX, comme *Knowlege eXtraction* sont, d'une part, les temps de réponse de différents sous-bassins à l'exutoire et, d'autre part, la contribution relative de ces sous-bassins au débit mesuré à l'exutoire. Cette démarche s'appuie sur une méthode de sélection des variables pour les modèles neuronaux qui calcule l'influence de chaque variable d'entrée sur la sortie, grâce aux paramètres du réseau de neurones. Cependant, la non-linéarité introduite par les neurones de la couche cachée n'est pas prise en compte.

Comme ces connaissances extraites ne sont pas mesurables sur le terrain, une validation de la méthode KnoX a été proposée, utilisant un modèle fictif. Cette validation a permis de donner un ordre de grandeur de la confiance à accorder aux connaissances extraites dans différents cas de figure : influence variable des sous-bassins, temps de réponses différents ou identiques. Le modèle fictif réalisé est d'une grande souplesse et permet de valider la méthode en fonction des besoins (nombre de sous-bassins, temps de réponse, contributions différentes) pour d'autres systèmes karstiques. La prise en compte de la non-linéarité dans le calcul des contributions de chaque entrée pourrait permettre l'augmentation de la précision de cette méthode.

La méthode KnoX a ensuite été appliquée au bassin d'alimentation de la source du Lez, se basant sur les connaissances géologiques de ce bassin pour déterminer quatre sous-bassins d'alimentation. Les résultats, en accord avec les connaissances actuelles du système, ont permis de préciser les contributions relatives des sous-bassins d'alimentation, et même de redéfinir le périmètre de la zone de recharge de la source du Lez. En effet la zone la plus au sud du bassin a une contribution très faible qui suggère qu'elle doit être retirée de cette zone de recharge. De plus, le karst dans cette zone est sous-couverture, et en aval de la source du Lez, il ne peut donc être alimenté directement par la pluie. En revanche cette zone correspond en réalité à une partie de la zone d'influence du pompage à la source du Lez et, si elle peut être supprimée de la zone de recharge, ne peut donc être ôtée du bassin d'alimentation (P. Bérard, 1983).

Pour la zone Nord-Ouest, deux temps de réponse ont été mis en évidence par la méthode KnoX. La connaissance de cette zone permet d'interpréter le deuxième temps de réponse comme le résultat d'une infiltration retardée par un aquifère perché, le Causse de l'Hortus.

La méthode KnoX a donc démontré son efficacité sur l'aquifère karstique complexe du Lez, mais elle est applicable à tout hydrosystème pour lequel on dispose de données de pluie et de débit. Des connaissances préalables sur le système, notamment en termes de géologie sont nécessaires pour proposer le modèle postulé et affiner les interprétations.

Les perspectives d'amélioration de cette méthode sont nombreuses, en particulier pour la prise en compte de la non-linéarité du modèle pour estimer les contributions et les temps de réponse du système.

Conclusion

Les karsts sont des réservoirs aquifères très présents à la surface de la Terre qui fournissent près de 25% des ressources en eau potable de la population mondiale. Pourtant, ils constituent le type d'aquifère le moins bien compris à cause de fortes hétérogénéités de structure qui impliquent un fonctionnement parfois très non-linéaire.

L'aquifère karstique du Lez, qui a fait l'objet de cette étude, est un aquifère particulièrement complexe, doublant l'hétérogénéité du karst par une hétérogénéité géologique. Durant l'automne il est soumis à des épisodes pluvieux très intenses, difficilement prévisibles, tandis que son comportement, comme celui d'autres hydrosystèmes karstiques, est encore mal connu lors des crues. De plus, la source du Lez est exploitée pour alimenter une partie de l'agglomération de Montpellier (400 000 habitants) en eau potable. Le pompage intensif qui en résulte modifie donc le comportement de ce système en asséchant la source durant l'été, créant de ce fait un réservoir souterrain mobilisable pour écrêter les crues durant l'automne.

Le double enjeu : prévision des crues et meilleure connaissance hydrodynamique de l'aquifère karstique du Lez est donc l'objet du travail de cette thèse. Forts des nombreuses études qui se sont déroulées sur cet aquifère depuis plus de 50 ans et qui constituent un socle solide de connaissances, nous avons proposé de modéliser cet aquifère au moyen de l'apprentissage statistique, en particulier les réseaux de neurones, afin de compléter par une approche de type boîte noire les études déjà réalisées.

La première partie de cette thèse a donc présenté les karsts en général, les difficultés rencontrées pour les étudier et les méthodes existantes. La très forte hétérogénéité que peuvent présenter les aquifères karstiques ainsi que leur diversité – chaque karst a une structure et un fonctionnement propre - sont des freins importants a leur caractérisation et à l'établissement de méthodes génériques, applicables à tous les aquifères karstiques. Dans ce contexte, l'approche systémique qui considère le karst dans son ensemble, se basant sur l'étude de la transformation de la pluie en débit pour caractériser le fonctionnement des karsts, est potentiellement applicable à tout hydrosystème karstique pour lequel on dispose de données de pluie et de débit.

Dans la continuité de l'approche systémique, les réseaux de neurones apparaissent comme des outils adéquats, ayant déjà fait leurs preuves dans le domaine de l'hydrologie de surface. Leurs propriétés fondamentales : la parcimonie et l'approximation universelle ont été présentées, ainsi que les méthodes permettant d'éviter le surajustement qui est le principal écueil lors de l'utilisation de tels modèles.

L'aquifère du Lez a ensuite été présenté afin de mettre en évidence l'ensemble des travaux concernant l'hydrodynamique de ce système. Comme pour nombre d'aquifères karstiques, les limites du bassin d'alimentation sont parues comme incertaines et changeantes en fonction du niveau de remplissage. De plus, plusieurs comportements ont été mis en évidence en ce qui concerne les infiltrations, qui peuvent prendre des parcours divers, l'eau suivant des trajets complexes par des pertes et exsurgences successives, différents en fonction de la zone géologique concernée.

Dans ce contexte très complexe, l'application de modèles neuronaux à la simulation et à la prévision des débits de la source du Lez a donné des résultats très satisfaisants jusqu'à un horizon de prévision de un jour, sans prévision ni hypothèse sur la pluviométrie. De plus, la comparaison du modèle neuronal avec un modèle à réservoirs pour la simulation des débits et de la piézométrie de la source du Lez a été effectuée, et a démontré la robustesse du modèle neuronal, qui s'est avéré assez peu sensible à la manière dont était prise en compte l'évapotranspiration comme variable d'entrée. Ceci constitue un atout important dans notre domaine d'étude où les données ne sont pas toujours disponibles.

Dans la dernière partie de ce travail, la méthode KnoX permettant l'extraction de données physiquement interprétables à partir du réseau de neurones a été proposée. Elle consiste à contraindre le réseau dans son architecture, en fonction des connaissances disponibles sur le système à étudier, ici la géologie. L'application d'une méthode initialement développée pour la sélection de variables a permis d'extraire les temps de réponse et les contributions des sousbassins d'alimentation de la source au débit à l'exutoire principal du karst. Un hydrosystème fictif a également été développé afin de valider la méthode. L'application de la méthode KnoX à la source du Lez a permis de reconsidérer l'étendue de la zone de recharge de la source et de préciser les connaissances hydrodynamiques concernant ce bassin par l'identification de plusieurs temps de réponse, de un jour à trois jours en fonction de la localisation des précipitations.

Ce travail de thèse a donc permis de montrer d'une part l'efficacité des modèles par réseaux de neurones pour la simulation et la prévision des débits de sources karstiques, et d'autre part l'utilité de ce type de modèle dans la compréhension du fonctionnement hydrodynamique des karsts par l'intermédiaire d'une méthode originale d'extraction des connaissances contenues dans le modèle : la méthode KnoX.

Cette dernière apparaît comme une méthode applicable à tout hydrosystème pour lequel on dispose de mesures de pluie et de débit, ainsi que d'une solide connaissance géologique, mais dont l'hydrodynamique est peu quantifiée. Il reste cependant à appliquer cette méthode à d'autres aquifères afin de valider son caractère transposable à d'autres contextes pluviométriques, géologiques et géomorphologiques.

Références bibliographiques

- Abbott, M.B., Bathurst, J.C., Cunge, J.A. O'Connell, P.E. & Rasmussen, J. (1986) Introduction to the European Hydrological System- Systeme Hydrologique Europeen, 'SHE', Structure of a Physically-based, Distributed Modelling System. *Journal of Hydrology* JHYDA 7, 87(1-2).
- Andreassian, V., Perrin, C., Michel, C., Usart-Sanchez, I. & Lavabre, J. (2001) Impact of imperfect rainfall knowledge on the efficiency and the parameters of watershed models. *Journal of Hydrology*, 250(1-4), pp.206-223.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000a) Artificial Neural Networks in Hydrology. I: Preliminary Concepts. *Journal of hydrologic engineering*. 5 (2): 115-123
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000b) Artificial Neural Networks in Hydrology. II: Hydrologic Applications. *Journal of hydrologic engineering* 5 (2): 124-137
- Atkinson, T., Smith, D., Lavis, J., & Witaker, R. (1973) Experiments in tracing underground waters in limestones. *Journal of Hydrology*, 19(4), 323-349. doi: 10.1016/0022-1694(73)90106-6.
- Audra, P., Mocochain, L., Camus, H., Gilli, E., Clauzon, Georges, & Bigot, J.-Y. (2004) The effect of the Messinian Deep Stage on karst development around the Mediterranean Sea. Examples from Southern France. *Geodinamica Acta*, 17(6), 389-400. doi: 10.3166/ga.17.389-400.
- Avias, J. (1995) Active management of Lez karstic spring, Herault, France, 1957-1994. *Hydrogeologie Editions du BRGM*, 113–128.
- 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.
- Bailly-Comte, V. (2008). Interactions hydrodynamiques surface/souterrain en milieu karstique. Approche descriptive, analyse fonctionnelle et modélisation hydrologique appliquées au bassin versant du Coulazou, Causse d'Aumelas, France. Thèse Université Montpellier II.
- Bailly-Comte, V., Jourde, H., Roesch, A., Pistre, S. & Batiot-Guilhe, C. (2008). Time series analyses for karst/river interactions assessment: Case of the Coulazou river (southern France), *Journal of hydrology*, 349 (1-2): 98-14.
- Bailly-Comte, V., Jourde, H. & Pistre, S. (2009). Conceptualization and classification of groundwater-surface water hydrodynamic interactions in karst watersheds: Case of the karst watershed of the Coulazou River (Southern France). *Journal of Hydrology*, 376(3-4), pp. 456-462.

- 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.
- Bakalowicz, M. (2008). Le milieu karstique : études et perspectives, identification et caractérisation de la ressource. In *Colloque Hygrogéologie et Karst au travers des travaux de Michel Lepillers*, pp.11-27.
- Barron, A. R. (1993). Universal approximation bounds for superpositions of a sigmoidal function. *IEEE Transactions on Information theory*, 39(3).
- Bartholmes, J. & Todini, E. (2005). Coupling meteorological and hydrological models for flood forecasting. *Hydrol. Earth Syst. Sci.*, 9(4) pp 333-346.
- Beven, K.J., Warren, R. & Zaoui, J. (1980). SHE: towards a methodology for physically-based distributed forecasting in hydrology. *IAHS Publ*, 129.
- Beven, K., Kirkby M.J., Schofield, N., Tagg A.N. (1984). Testing a physically-based flood forecasting model (TOPMODEL) for three U.K. catchments. *Journal of Hydrology*, 69(1-4), pp. 119-143.
- Bonnet, M., & Mattauer, M. (2010). Notice de la carte géologique 1/50 000 Montpellier (2nd ed.). BRGM.
- Botton, R. (1984). Etude *de certaines modalités du fonctionnement de l'aquifère karstique 543 (zone d'infiltration et zone saturée) sur deux champs de forages nord-montpellierains*. These Université Montpellier II Sciences et Techniques du Languedoc, Montpellier, France.
- Bouttier, F. (2003). The AROME mesoscale project. In Proceedings of a seminar on Recent developments in data assimilation for atmosphere and ocean. pp. 8–12.
- 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), pp. 1010-1021
- Campolo, M., Soldati, A. & Andreussi, P. (1999). Forecasting river flow rate during low-flow periods using neural networks. *Water Resources Research*, 35(11), pp.3547-3552.
- Caetano Bicalho, C. (2010). *Hydrochemical characterization of transfers in karst aquifers by natural and anthropogenic tracers*. *Example of a Mediterranean karst system , the Lez karst aquifer (Southern France).* Thèse Agro Paris Tech.

- Chemin, J. (1974). Essai d'application d'un modèle mathématique conceptuel au calcul du bilan hydrique de l'aquifère karstique de la source du Lez (Région Nord de Montpellier). Thèse Université Montpellier II Sciences et Techniques du Languedoc.
- Chiang, Y.M., Chang, L.C. & Chang, F.J. (2004). Comparison of static-feedforward and dynamic-feedback neural networks for rainfall-runoff modeling. *Journal of Hydrology*, 290(3-4), pp. 297–311.
- Clauzon, G. (1982). Le canyon messinien du Rhône: une preuve décisive du "desiccated deep-basin model" [Hsü, Cita et Ryan, 1973]". Bulletin de la Société géologique de France, Océans-paléocéans, Paris, 24(3), 597-610.
- Cloke, H. & Pappenberger, F. (2009). Ensemble flood forecasting: A review. *Journal of Hydrology*, 375(3-4), pp. 613-626.
- Conroux, Y. (2007). *Caractérisation du fonctionnement hydrodynamique de l'aquifère karstique du Lez (Hérault) à l'état naturel,* Rapport de Master, BRGM Montpellier.
- Cooper, V., Nguyen, V.T.V. & Nicell, J.A. (2007). Calibration of conceptual rainfall-runoff models using global optimisation methods with hydrologic process-based parameter constraints. *Journal of Hydrology*, 334(3-4), pp.455-466.
- Cornaton, F. & Perrochet, P. (2002). Analytical 1D dual-porosity equivalent solutions to 3D discrete single-continuum models. Application to karstic spring hydrograph modelling. *Journal of Hydrology*, 262(1-4), 165–176.
- Cornaton, F. & Perrochet, P. (2002). Analytical 1D dual-porosity equivalent solutions to 3D discrete single-continuum models. Application to karstic spring hydrograph modelling. *Journal of Hydrology*, 262(1-4), pp. 165–176.
- Coulibaly, P., Anctil, F., Rasmussen P., Bobée B. (2000a). A recurrent neural networks approach using indices of low-frequency climatic variability to forecast regional annual runoff. *Hydrological Processes*, 14(15), pp. 2755-2777.
- Coulibaly, P., Anctil, F., Bobée, B. (2000b). Daily reservoir inflow forecasting using artificial neural networks with stopped training approach, *Journal of Hydrology* 230(3-4), pp. 244-257.
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems*, 2(4), pp.303-314.
- Dae-II, J. & Young-Oh, K. (2005). Rainfall-runoff models using artificial neural networks for ensemble streamflow prediction. *Hydrological processes*, 19(19), 3819–3835.
- Delrieu, G., Nicol J., Yates, E., Kirstetter P-E., Creutin J-D., Anquetin, S., Obled, C., Sauliner G.M., Ducrocq, V., Gaume E., Payrastre, O., Andrieu, H., Ayral, P-A., Bouvier, C., Neppel, L., Livet, M., Lang, M., Parent-duChâtelet, J., Walpersdorf, A., Wobrock, W. (2005). The Catastrophic Flash-Flood Event of 8–9 September 2002 in the Gard

Region, France: A First Case Study for the Cévennes-Vivarais Mediterranean Hydrometeorological Observatory. *American Meteorological Society Journal*, 6(1).

- DeVos, N. J., & Rientjes, T. H. M. (2008). Multiobjective training of artificial neural networks for rainfall-runoff modeling. *Water Resources Research.*
- 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.
- Dreybrodt, W. (1998). Limestone dissolution rates in karst environments. *Bulletin d'hydrogéologie*, 16, pp.167-183.
- Dreyfus, G. (2005). Neural Networks : Methodology and Applications. Springer
- Drogue, 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.
- Drogue, C. & Grillot, J.C. (1976). Structure geologique et premieres observations piezometriques a la limite du sous-systeme karstique de Terrieu (Perimetre experimental). *Ann. Sc. Univ. Besancon*, 25, 195-210.
- Durand, V. (1992). Structure d'un massif karstique. Relations entre déformations et facteurs hydro-météorologiques. Causse de l'Hortus site des sources du Lamalou (Hérault), Thesis, Doctorat en Géologie, Thèse Université Montpellier II Sciences et Techniques du Languedoc, Montpellier, France.
- Eisenlohr, L., Kiraly, L., Bouzelboudjen, M. & Rossier, Y. (1997). Numerical simulation as a tool for checking the interpretation of karst spring hydrographs. *Journal of Hydrology*, 193(1-4), pp.306-315.
- Fleury, P., (2005). Sources sous-marines et aquifères karstiques côtiers méditerranéens. Fonctionnement et caractérisation. Thèse Université Pierre et Marie Curie, Paris, 286 p.
- 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), pp.38-49.
- Fleury, P., Ladouche, B., Conroux, Y., Jourde, H. & Dörfliger, N. (2008). Modelling the hydrologic functions of a karst aquifer under active water management The Lez spring. *Journal of Hydrology*, 365(3-4), pp.235-243.
- Ford, D.C. & Williams, P.W. (2007). *Karst Geomorphology and Hydrology*, Chichester, England: John Wiley & Sons.

- Formigué, P. & Lavabre, J. (2005). Flood forecasting with the GR3J conceptual rainfall-runoff model. Adaptability to rainfall uncertainties. *Journal of Water Science*, 18(1), pp. 87-102.
- Funahashi, K. (1989). On the approximate realization of continuous mappings by neural networks, *Neural Networks*, 2(3), pp.183-192.
- Gaume, E. & Bouvier, C. (2004). Analyse hydro-pluviométrique des crues du Gard et du Vidourle des 8 et 9 septembre 2002 : Crues Méditerranéennes : l'aléa et la gestion de crise = Hydrological analysis of the Gard and Vidourle river floods on the 8th and 9th September 2002. *La Houille Blanche*, (6).
- Gaume, E. & Gosset R. (2003). Overparametrization a major obstacle to the use of neural networks in hydrology, *Hydrology and Earth System Sciences* 7(5), pp. 693-706.
- Gaume, E., Bain, V., Bernardara, P., Newinger, O., Barbuc, M., Bateman, A., Blaškovičová, L., Blöschl, G., Borga, M. & Dumitrescu A. (2009). A compilation of data on European flash floods. *Journal of Hydrology*, 367(1-2), 70-78. doi: 10.1016/j.jhydrol.2008.12.028.
- Geman, S., Bienenstock, E. & Doursat, R. (1992) Neural networks and the bias/variance dilemma. *Neural Computation* 4(1), pp. 1–58
- Gèze, B. (1979). Languedoc méditerranéen. Montagne Noire. Masson.
- Govindaraju, R.S. (2000). Artificial neural networks in hydrology. I: Preliminary concepts. *Journal of Hydrologic Engineering*, 5(2), pp. 115-123.
- Guilbot, A. (1975). *Modélisation des écoulements d'un aquifère karstique (Liaison pluie-débit). Application aux bassins de Saugras et du Lez.* Thèse Université Montpellier II Sciences et Techniques du Languedoc.
- Hagan, M.T. & Menhaj, M.B. (1994). Training feedforward networks with the Marquardt algorithm. *Neural Networks, IEEE Transactions on*, 5(6), pp.989-993.
- Halff, A. H., Halff, H.M. & Azmoodeh, M. (1993). Predicting runoff from rainfall using neural networks. In *Proc. Engng. Hydrol.*, ASCE, New York, pp. 768-775
- Hornik, K., Stinchcombe, P. & White, H. (1989). Multilayer feed-forward neural networks are universal approximator, *Neural Networks* 2, pp. 359-366
- Hreiche, A. (2003) *Modélisation conceptuelle de la transformation pluie-débit dans le contexte méditerranéen*. Thèse Université Montpellier II et Université Saint-Joseph
- Hsu, K.L., Gupta, H.V. & Sorooshian, S. (1995) Artificial neural network modeling of the rainfall-runoff process, *Water Resources Research* 31(10), pp. 2517-2530.
- Jaquet, O., Siegel, P., Klubertanz, G., Benabderrhamane, H. (2004). Stochastic discrete model of karstic networks. *Advances in Water Resources*, 27(7), pp. 751–760.

- Jain, A., & Sumant, K. (2009) Dissection of trained neural network hydrologic models for knowledge extraction. *Water Resources Research* 45.
- Jain, A., Sudheer, K.P. & Srinivasulu, S. (2004). Identification of physical processes inherent in artificial neural network rainfall runoff models. *Hydrological Processes*, 18(3), pp.571-581. Available at: http://dx.doi.org/10.1002/hyp.5502.
- Javelle, P., Berthet, L., Arnaud, P., Lavabre, J., Perrin, C. (2008). Comparaison de deux versions du modèle GR pour la prévision des crues sur un grand échantillon de bassins versants français. In *Colloque SHF-191e CST «Prévisions hydrométéorologiques»*, Lyon, 18-19 novembre 2008.
- Jazayeri Noushabadi, M. R. (2009). *Characterisation of relationship between fracture network and flow-path network in fractured and karstic reservoirs. Numerical modelling and field investigation (Lez aquifer, Southern France).* Thèse Université Montpellier II Sciences et Techniques du Languedoc.
- Jenkins, G.M. & Watts, D.G. (1968). Spectral Analysis and its Applications, Holden-Day.
- Johannet, A., Mangin, Alain & D'Hulst, D. (1994). Subterranean water infiltration modelling by neural networks : use of water source flow. In *International Conference on Artificial Neural Networks ICANN 94. Vol II.* pp. 1033-1036.
- Johannet, A., Mangin, A. & Vayssade, B. (2008a). Modélisation d'un système karstique par réseaux de neurones: simulation des débits du karst du Baget-France. *Collection EDYTEM Cahiers de Géographie*, (7).
- 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).
- Johannet, A., (2011). Modélisation par apprentisage statistique des systèmes naturels, ou en intéraction avec un environnement naturel. Application aux karsts, crues éclair et en robotique. Mémoire d'Habilitation à Diriger les Recherches. Université Pierre et Marie Curie.
- Jourde, H., Roesch, A., Guinot, V. & Bailly-Comte, V. (2007) Dynamics and contribution of karst groundwater to surface flow during Mediterranean flood, *Environemental Geology* 51(5), pp. 125-730.
- Jukić, D. & Denić-Jukić, V. (2009). Groundwater balance estimation in karst by using a conceptual rainfall-runoff model. *Journal of Hydrology*, 373(3-4), pp.302-315.
- 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.
- Kaufmann, G. & Romanov, D. (2008). Cave development in the Swabian Alb, south-west Germany: A numerical perspective. *Journal of Hydrology*, 349(3-4), pp. 302–317.

- Kitanidis, P. K., & Bras, R. L. (1980). Real-time forecasting with a conceptual hydrologic model. 2. Application and results. *Water Resources Research*, *16*(6), 1034-1044.
- Klimchouk, A. (2004). Towards defining, delimiting and classifying epikarst: Its origin, processes and variants of geomorphic evolution. *Speleogenesis and Evolution of Kars Aquifer*, 2(1).
- Kong A Siou, L., Johannet, A., Borrell, V. & Pistre, S. (2011a). 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), pp. 367-380.
- Kong A Siou, L., Johannet, A., Borell Estupina, V. & Pistre, S. (2011b). Optimization of the generalization capability for rainfall-runoff modeling by neural networks: The case of the *Lez* aquifer (southern France), *Environmental Earth Sciences*, accepté.
- Kurtulus, B. & Razack, M. (2007). Evaluation of the ability of an artificial neural network model to simulate the input-output responses of a large karstic aquifer: the La Rochefoucauld aquifer (Charente, France). *Hydrogeology Journal*, 15(2), pp.241-254.
- Labat, D., Ababou, R. & Mangin, A. (1999). Analyse en ondelettes en hydrologie karstique.
 2ème partie : analyse en ondelettes croisée pluie-débit. *Comptes Rendus de l' Académie des Sciences Sciences de la Terre et des Planètes*, 329, pp.881-887.
- Labat, D., Ababou, R., & Mangin, A. (2000). Rainfall-runoff relations for karstic spring. Part II: continuous wavelet and orthogonal multiresolution analyses, *Journal of Hydrology*, 238, pp. 149-178.
- Labat, D., Ababou, R. & Mangin, A. (2001). Introduction of Wavelet Analyses to Rainfall/Runoffs Relationship for a Karstic Basin: The Case of Licq-Atherey Karstic System (France). *Ground Water*, 39(4), pp.605-615.
- Labat, D., Ababou, R. & Mangin, A. (2002). Analyse multirésolution croisée de pluies et débits de sources karstiques - Multiresolution cross-analysis of rainfall rates and karstic spring runoffs. *Comptes Rendus Geosciences*, 334(8), pp.551-556.
- Lacas, J.L. (1976). Introduction à la méthodologie d'étude et d'utilisation des champs hydrothermiques des aquifères karstiques: d'après l'exemple du site de l'exsurgence de la source du Lez (Hérault, France). Thèse Université Montpellier II Sciences et Techniques du Languedoc, Montpellier, France.
- Lacas, J.L. & Avias, J., (1976). Introduction à la méthodologie d'étude et d'utilisation des champs hydrothermiques des aquifères karstiques: d'après l'exemple du site de l'exsurgence de la source du Lez (Hérault, France), Université des sciences et techniques du Languedoc (Montpellier), CERGA.

- Larocque, M., Mangin, A., Razack, M. & Banton, O. (1998). Contribution of correlation and spectral analyses to the regional study of a large karst aquifer (Charente, France). *Journal of Hydrology*, 205(3-4), pp.217-231.
- Lastennet, R. & Mudry, J. (1997). Role of karstification and rainfall in the behavior of a heterogeneous karst system. *Environmental Geology*, 32(2), pp.114-123.
- Le Lay, M. & Saulnier, G. (2007). Exploring the signature of climate and landscape spatial variabilities in flash flood events: Case of the 8-9 September 2002 Cévennes-Vivarais catastrophic event. *Geophysical Research Letters*, 34(13).
- Liden, R. & Harlin, J. (2000). Analysis of conceptual rainfall–runoff modelling performance in different climates. *Journal of Hydrology*, 238(3-4), pp.231-247.
- Liu, Z. & Todini, E. (2002). Towards a comprehensive physically-based rainfall-runoff model. *Hydrology and Earth System Sciences*, 6(5), pp. 859-881.
- Llasat, M.C., Llasat-Botija, M., Prat, M.A., Porcu, F., Price, C., Mugnai., Lagouvardos, K., Ktroni, V., Katsanos, D., Michaelides, S., Yair, Y., Savvidou., Nicolaides, K. (2010). High-impact floods and flash floods in Mediterranean countries: the FLASH preliminary database. *Advances in Geosciences*, 23, pp. 47-55.
- Long, A.J. (2009). Hydrograph separation for karst watersheds using a two-domain rainfalldischarge model. *Journal of Hydrology*, 364(3-4), pp. 249–256.
- Maier, H.R., & Dandy, G.C. (1996). The use of artificial neural networks for the prediction of water quality parameters, *Water Resources Research* 4(32), 1013-1022.
- 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.
- Maier, H.R., Jain, A., Dandy, G.C. & Sudheer, K. (2010). Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions. *Environmental Modelling & Software* 25 pp.891-909
- Mangin, A. (1975). *Contribution à l'étude hydrodynamique des aquifères karstiques*. Thèse Université de Dijon. Laboratoire souterrain du Centre national de la recherche scientifique.
- 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. (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. (1998). L'approche hydrogéologique des karsts. Spéléochronos (Mons), (9), pp.3-26.

- Marchandise, A. (2007). Modélisation hydrologique distribuée sur le Gardon d'Anduze: étude comparative de différents modèles pluie-débit, extrapolation de la normale à l'extrême et tests d'hypothèses sur le processus hydrologiques. Thèse Université des Sciences et Techniques du Languedoc (Montpellier).
- Maréchal, J., Ladouche, B. & Dörfliger, N. (2008). Karst flash flooding in a Mediterranean karst, the example of Fontaine de Nîmes. *Engineering Geology*, 99(3-4), pp. 138-146.
- 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 karsts à partir des résultats expérimentaux. Thèse Université Paris XI Orsay.

MEDYCYSS : http://www.medycyss.org/

- Mocochain, L., Clauzon, Georges, Bigot, J.-Y., & Brunet, P. (2006). Geodynamic evolution of the peri-Mediterranean karst during the Messinian an the Pliocene: evidence from the Ardèche and Rhône valley systems canyon, Southern France. *Sedimentary Geology*, 188-189, 219-233.
- Mohrlok, U. & Sauter, M. (1997). Modelling groundwater flow in a karst terrane using discrete and double-continuum approaches; importance of spatial and temporal distribution of recharge. In *Proceedings of the 12th International Speleological Congress*, pp. 167–170.
- Mohrlok, U. & Teutsch, G. (1997). Double continuum porous equivalent (DCPE) versus discrete modelling in karst terranes. In *Proceedings of the International Symposium and Field Seminar on Karst*. pp. 319–326.
- 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), pp.165-199.
- Nash, J.E. & Sutcliffe, J.V. (1970). River flow forecasting through conceptual models part I --A discussion of principles. *Journal of Hydrology*, 10(3), pp.282-290.
- Oussar, Y. & Dreyfus, G. (2001). How to be a gray box: dynamic semi-physical modeling. *Neural Networks*, 14(9), pp.1161-1172. Press, W.H., Teukolsky, S.A., Vetterling, W. & Flannery, B.P., 1992. *Numerical recipes in C*, Cambridge University Press.
- 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.
- Piotrowski, A., Napiorkowski, J.J. & Rowinski, P.M. (2006), Flash-flood forecasting by means of neural networks and nearest neighbour approach - a comparative study. *Nonlinear Processes in Geophysics*, 13(4), pp. 443–448.

- Rimmer, A. & Salingar, Y. (2006). Modelling precipitation-streamflow processes in karst basin: The case of the Jordan River sources, Israel. *Journal of Hydrology*, 331(3-4), pp.524-542.
- Roesch, A., & Jourde, H. (2006). Incidence d'une gestion active de la ressource en eau en milieu karstique sur le risque hydrologique. Exemple du fleuve Lez (Montpellier, France). *GIRE3D Congrès international*. Marrakech (Marocco).
- Rumelhart, D.E., Hintont, G.E. & Williams, R.J. (1986). Learning representations by backpropagating errors. *Nature*, 323(6088), pp.533-536.
- Sahoo, G. & Ray, C. (2006). Flow forecasting for a Hawaii stream using rating curves and neural networks. *Journal of Hydrology*, 317(1-2), pp. 63-80.
- Sahoo, G.B., Ray, C. & Carlo, E.H.D. (2006). Use of neural network to predict flash flood and attendant water qualities of a mountainous stream on Oahu , Hawaii. , pp.525-538.
- Sajikumar, N. & Thandaveswara, B.S. (1999) A non-linear rainfall-runoff model using an artificial neural network, *Journal of Hydrology* 216(1-2), pp. 32-55.
- Schmitz, G.H. & Cullmann, J. (2008) PAI-OFF: A new proposal for online flood forecasting in flash flood prone catchments, *Journal of Hydrology* 360, pp. 1-14.
- Schoups, G., Giesen, N. & Savenije, H. (2008). Model complexity control for hydrologic prediction, *Water Resources Research* 44.
- Sjöberg, J., Zhang, Q., Ljung, L., Benveniste, A., Deylon, B., Glorennec, P.Y., Hjalmarsson, H., Juditsky, A. (1995). Nonlinear Black-Box Modeling in System Identification : a Unified Overview. *Automatica*, 31(12), pp.1691-1724.
- Stone, M., (1974). Cross-Validatory Choice and Assessment of Statistical Predictions. *Journal* of the Royal Statistical Society. Series B (Methodological), 36(2), pp.111-147.
- Sudheer, K.P., Gosain, A.K. & Ramasastri, K.S. (2002). A data-driven algorithm for constructing artificial neural network rainfall-runoff models. *Hydrological Processes*, 16(6).
- Sudheer, K.P., Nayak, P.C. & Ramasastri, K.S. (2003). Improving peak flow estimates in artificial neural network river flow models. *Hydrological Processes*, 17(3), pp. 677–686.
- Touet, F. (1987). Détermination de l'origine des ressources en eau captées en bordure Sud du pli de Montpellier entre Montpellier et Vendargues (Hérault). Thèse Université Paris-Sud 11.
- Thiery, D. (2004). Plaquette de présentation du code de calcul GARDÉNIA du BRGM Note technique.

- 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.
- 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
- Toukourou, M.S. (2007). La modélisation de la relation Pluie-Hauteur d'eau. Rapport de 1^{ère} année de thèse. Ecole des Mines d'Alès.
- Toukourou, M.S., 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*, pp.98-107.
- Toukourou, M.S. (2009). Application de l'apprentissage artificiel à la prévision des crues éclair. Thèse Ecole des Mines de Paris.
- Toukourou, M.S., Johannet, A., Dreyfus, G. & Ayral, P.A. (2010). Rainfall-runoff modeling of flash floods in the absence of rainfall forecasts: the case of "Cevenol flash floods." *Journal of Applied Intelligence*, In press.
- Vincendon, B., Ducrocq, V., Saulnier, G.M., Bouilloud, L., Chancibault, K., Habets, F., Noilhan, J. (2010). Benefit of coupling the ISBA land surface model with a TOPMODEL hydrological model version dedicated to Mediterranean flash-floods. *Journal of Hydrology*, 394(1-2), pp. 256-266.
- Vinet, F. (2008). Geographical analysis of damage due to flash floods in southern France: The cases of 12–13 November 1999 and 8–9 September 2002. *Applied Geography*, 28(4), 323-336. doi: 10.1016/j.apgeog.2008.02.007.
- Wilby, R.L., Abrahart, R.J. & Dawson, C.W. (2003). Detection of conceptual model rainfall runoff processes inside an artificial neural network. *Hydrological Sciences Journal*, 48(2), pp.163-181.
- Yacoub, M., & Bennani Y. (1997). A heuristic variable selection in multilayer artificial neural network classifier, *Intelligent Engineering System Through Artificial Neural Networks* 7, pp. 527-532.
- Zealand, C.M., Burn, D.H. & Simonovic, S.P. (1997). Short term streamflow forecasting using artificial neural networks, *Journal of Hydrology* 214(1-4), pp. 32-48.
- Zhang, G., Patuwo, E.B. & Hu, M. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14(1), pp. 35–62.

- **Bande passante** : En traitement du signal, intervalle de fréquences pour lesquelles le signal (en puissance) est supérieur à son maximum divisé par 2.
- **Biseau salé** : Partie d'un aquifère remplie d'eau salée. Un biseau salé est généralement observable dans les aquifères côtiers, l'eau de mer envahissant la partie la plus proche de la côte, sous l'eau douce. Dans un aquifère de structure homogène (aquifère poreux par exemple), l'interface eau douce-eau salée est linéaire. L'exploitation de l'aquifère peut modifier la position du biseau salé.
- **Décolmatage** : Evacuation des dépôts d'une galerie ou d'une fissure qui aboutit à la restitution de la perméabilité initiale de cette galerie ou fissure.
- **Densité de drainage :** Introduite par Horton, la densité de drainage rend compte de l'importance du développement d'un réseau permettant la circulation de l'eau. Elle s'exprime en km/km² et correspond à la longueur totale du réseau hydrographique par unité de surface du bassin versant :

$$d = \frac{\sum L_i}{A}$$

Avec L_i la longueur des cours d'eau ou drains et A la surface du bassin versant ou de l'hydrosystème considéré.

- **Exutoire** : Point le plus en aval hydraulique d'un hydrosystème qui concentre ses écoulements
- **Gradient hydraulique** : Variation de la charge hydraulique par unité de longueur. Dans le cas d'un hydrosystème souterrain, la charge hydraulique en un point est égale à la piézométrie.
- **Infiltration diffuse et infiltration concentrée** : L'infiltration diffuse se produit sur des surfaces perméables. L'infiltration concentrée se produit au niveau de point particuliers tels que des puits qui permettent à l'eau de surface de s'infiltrer rapidement.
- **Jaugeage** : Mesure de débit. Effectuer un jaugeage consiste à mesurer la vitesse du courant (à l'aide d'un moulinet par exemple) à plusieurs endroits de la section d'une rivière pour permettre le calcul du débit.
- Manteau (Lithosphérique) : Couche de la Terre située en dessous de la croûte terrestre à plusieurs dizaines de kilomètres (environ 30 à 70 km pour une croûte continentale, moins de 10 km pour une croûte océanique) sous la surface et d'une épaisseur de plus de 100 km environ.
- **Modèle déterministe** : Modèle basé sur les connaissances que l'on a du processus à modéliser, et ne faisant pas appel au calcul de probabilités.
- **Modèle stochastique** : Modèle basé sur les mesures dont on dispose du processus à modéliser et faisant appel au calcul de probabilités.
- **NGF** : Nivellement Général de la France. Altitude mesurée en mètres par rapport au 0 m NGF qui est, dans le cas de la France métropolitaine, le niveau de la mer à Marseille.
- **Niveau de base** : Altitude la plus basse vers laquelle vont les écoulements. Pour les aquifères côtiers, le niveau de base correspond au niveau de la mer.
- **Piézométrie** : Mesure de la hauteur d'eau dans un forage. Le niveau piézométrique correspond au niveau libre de l'eau observée dans le forage rapporté à un niveau de référence (ici le niveau NGF)
- **Perméabilité** : Caractéristique physique d'un matériau qui rend compte de la capacité à laisser circuler un fluide au sein d'un réseau connecté. La perméabilité s'exprime en m².
- **Perte** : Lieu où un écoulement disparaît de la surface pour devenir souterrain. En domaine karstique, les pertes sont généralement des gouffres ou des puits.
- **Porosité** : Rapport entre le volume des vides d'un matériau et le volume total de ce matériau. La porosité s'exprime en %.
- **Régénération arrière** : Se dit d'un amas orageux dont les cellules orageuses renaissent en permanence au point le plus en arrière par rapport au flux directeur.
- Signal stationnaire : Signal dont les propriétés statistiques sont indépendantes du temps.
- **Trop-plein** : Une source de trop-plein est une source temporaire qui évacue de l'eau lorsque l'aquifère est saturé.
- **V.E.R.** : (Volume élémentaire représentatif) En hydrogéologie, plus petit volume pour lequel une valeur mesurée peut être considérée comme étant représentative de tout l'aquifère.

Annexe A : Interprétation des corrélogrammes

Cette annexe présente les calculs permettant d'exploiter les corrélogrammes, et plus particulièrement de déterminer le seuil à partir duquel les deux séries sont considérées comme indépendantes l'une de l'autre. Pour faciliter la lecture, les équations permettant de calculer le coefficient de corrélation croisée c_k sont rappelées ci-dessous. Il faut noter que le coefficient de corrélation simple se calcule de la même manière, avec une seule série chronologique (x=y). Les calculs suivants sont écrits pour la corrélation croisée mais sont donc applicables pour la corrélation simple.

$$r_k = \frac{C_k}{S_x S_y}$$
 Équation 39

avec r_k le coefficient de corrélation normalisé, C_k le coefficient de corrélation défini ci-dessous, k le décalage en jours, x la chronique de pluviométrie et y la chronique de débit, et S_x et S_y les écarttypes correspondants à x et y respectivement.

$$C_{k} = \frac{1}{n} \sum_{i=1}^{i=n-k} [(x_{i} - \bar{x})(y_{i+k} - \bar{y})]$$
 Équation 40

avec c_k le coefficient de corrélation et n le nombre de mesures

Pour déterminer le seuil de corrélation à partir duquel les deux séries sont indépendantes, il faut déterminer l'erreur sur l'estimation de C_k . L'intervalle de confiance calculé sur c_k permet de connaître le seuil à partir duquel r_k peut être considéré comme égal à o.

Deux cas sont à distinguer : le nombre de mesure est grand (n > 300) ou plus réduit ($n \le 300$)

a) Grand nombre de mesures (n > 300)

Dans ce cas on considère que le coefficient de corrélation suit une loi de distribution normale. On peut alors déterminer l'intervalle de confiance de r_k de la façon suivante :

L'intervalle de confiance au seuil de 95% est de $r_k \pm 1,96. \sigma_r$.

Et l'intervalle de confiance au seuil de 99% est de $r_k \pm 2,58. \sigma_r$.

avec
$$\sigma_r = \frac{1 - r_k^2}{\sqrt{n-1}} \cong \frac{1 - r_k^2}{\sqrt{n}}$$
 Équation 41

Si n=365 jours, l'application numérique donne, au seuil de 5% $r_k \pm 0,10$ et au seuil de 1% $r_k \pm 0,13$

b) Nombre de mesures réduit ($n \le 300$)

Dans ce cas la distribution du coefficient de corrélation ne peut être considérée comme normale, on utilise alors un paramètre intermédiaire qui est lié à c_k par l'équation 42 et qui est distribué selon une loi normale. L'intervalle de confiance est alors calculé grâce au $\sigma_z \sigma_z$ donné par l'équation 43.

$$z = \frac{1}{2} \log \left(\frac{1 + r_k}{1 - r_k} \right)$$
 Équation 42

$$\sigma_z = \frac{1}{\sqrt{n-3}}t$$

Équation 43

| | | Risque d'erreur 1-P | | | | | | | | | |
|-------|--------|---------------------|-------|-------|--------|--------|--------|--------|--------|--------|--------|
| | | 0.50 | 0.20 | 0.10 | 0.05 | 0.02 | 0.01 | 0.005 | 0.002 | 0.001 | 0.0001 |
| | 1 | 1.000 | 3.078 | 6.314 | 12.706 | 31.281 | 63.657 | 127.32 | 318.31 | 636.62 | 6366.2 |
| | 2 | 0.816 | 1.886 | 2.920 | 4.303 | 6.965 | 9.925 | 14.089 | 22.327 | 34.599 | 99.992 |
| | 3 | 0.765 | 1.638 | 2.353 | 3.182 | 4.541 | 5.841 | 7.453 | 10.215 | 12.924 | 28.000 |
| | 4 | 0.741 | 1.533 | 2.132 | 2.776 | 3.747 | 4.604 | 5.598 | 7.173 | 8.610 | 15.544 |
| | 5 | 0.727 | 1.476 | 2.015 | 2.571 | 3.365 | 4.032 | 4.773 | 5.893 | 6.869 | 11.178 |
| | 6 | 0.718 | 1.440 | 1.943 | 2.447 | 3.143 | 3.707 | 4.317 | 5.208 | 5.959 | 9.082 |
| | 7 | 0.711 | 1.415 | 1.895 | 2.365 | 2.998 | 3.499 | 4.029 | 4.785 | 5.408 | 7.885 |
| | 8 | 0.706 | 1.397 | 1.860 | 2.306 | 2.896 | 3.355 | 3.833 | 4.501 | 5.041 | 7.120 |
| | 9 | 0.703 | 1.383 | 1.833 | 2.262 | 2.821 | 3.250 | 3.690 | 4.297 | 4.781 | 6.594 |
| | 10 | 0.700 | 1.372 | 1.812 | 2.228 | 2.764 | 3.169 | 3.581 | 4.144 | 4.587 | 6.211 |
| | 11 | 0.697 | 1.363 | 1.796 | 2.201 | 2.718 | 3.106 | 3.497 | 4.025 | 4.437 | 5.921 |
| | 12 | 0.695 | 1.356 | 1.782 | 2.179 | 2.681 | 3.055 | 3.428 | 3.930 | 4.318 | 5.694 |
| | 13 | 0.694 | 1.350 | 1.771 | 2.160 | 2.650 | 3.012 | 3.372 | 3.852 | 4.221 | 5.513 |
| | 14 | 0.692 | 1.345 | 1.761 | 2.145 | 2.624 | 2.977 | 3.326 | 3.787 | 4.140 | 5.363 |
| | 15 | 0.691 | 1.341 | 1.753 | 2.131 | 2.602 | 2.947 | 3.286 | 3.733 | 4.073 | 5.239 |
| | 16 | 0.690 | 1.337 | 1.746 | 2.120 | 2.583 | 2.921 | 3.252 | 3.686 | 4.015 | 5.134 |
| N N | 17 | 0.689 | 1.333 | 1.740 | 2.110 | 2.567 | 2.898 | 3.222 | 3.646 | 3.965 | 5.044 |
| erté | 18 | 0.688 | 1.330 | 1.734 | 2.101 | 2.552 | 2.878 | 3.197 | 3.610 | 3.922 | 4.966 |
| e lib | 19 | 0.688 | 1.328 | 1.729 | 2.093 | 2.539 | 2.861 | 3.174 | 3.579 | 3.883 | 4.897 |
| édε | 20 | 0.687 | 1.325 | 1.725 | 2.086 | 2.528 | 2.845 | 3.153 | 3.552 | 3.850 | 4.837 |
| egr | 21 | 0.686 | 1.323 | 1.721 | 2.080 | 2.518 | 2.831 | 3.135 | 3.527 | 3.819 | 4.784 |
| le d | 22 | 0.686 | 1.321 | 1.717 | 2.074 | 2.508 | 2.819 | 3.119 | 3.505 | 3.792 | 4.736 |
| re c | 23 | 0.685 | 1.319 | 1.714 | 2.069 | 2.500 | 2.807 | 3.104 | 3.485 | 3.768 | 4.693 |
| mb | 24 | 0.685 | 1.318 | 1.711 | 2.064 | 2.492 | 2.797 | 3.091 | 3.467 | 3.745 | 4.654 |
| Nc | 25 | 0.684 | 1.316 | 1.708 | 2.060 | 2.485 | 2.787 | 3.078 | 3.450 | 3.725 | 4.619 |
| | 30 | 0.683 | 1.310 | 1.697 | 2.042 | 2.457 | 2.750 | 3.030 | 3.385 | 3.646 | 4.482 |
| | 35 | 0.682 | 1.306 | 1.690 | 2.030 | 2.438 | 2.724 | 2.996 | 3.340 | 3.591 | 4.389 |
| | 40 | 0.681 | 1.303 | 1.684 | 2.021 | 2.423 | 2.704 | 2.971 | 3.307 | 3.551 | 4.321 |
| | 45 | 0.680 | 1.301 | 1.679 | 2.014 | 2.412 | 2.690 | 2.952 | 3.281 | 3.520 | 4.269 |
| | 50 | 0.679 | 1.299 | 1.676 | 2.009 | 2.403 | 2.678 | 2.937 | 3.261 | 3.496 | 4.228 |
| | 60 | 0.679 | 1.296 | 1.671 | 2.000 | 2.390 | 2.660 | 2.915 | 3.232 | 3.460 | 4.169 |
| | 70 | 0.678 | 1.294 | 1.667 | 1.994 | 2.381 | 2.648 | 2.899 | 3.211 | 3.435 | 4.127 |
| | 80 | 0.678 | 1.292 | 1.664 | 1.990 | 2.374 | 2.639 | 2.887 | 3.195 | 3.416 | 4.096 |
| | 90 | 0.677 | 1.291 | 1.662 | 1.987 | 2.368 | 2.632 | 2.878 | 3.183 | 3.402 | 4.072 |
| | 100 | 0.677 | 1.290 | 1.660 | 1.984 | 2.364 | 2.626 | 2.871 | 3.174 | 3.390 | 4.053 |
| | 150 | 0.676 | 1.287 | 1.655 | 1.976 | 2.351 | 2.609 | 2.849 | 3.145 | 3.357 | 3.998 |
| | 200 | 0.676 | 1.286 | 1.653 | 1.972 | 2.345 | 2.601 | 2.839 | 3.131 | 3.340 | 3.970 |
| | 300 | 0.675 | 1.284 | 1.650 | 1.968 | 2.339 | 2.592 | 2.828 | 3.118 | 3.323 | 3.944 |
| | 500 | 0.675 | 1.283 | 1.648 | 1.965 | 2.334 | 2.586 | 2.820 | 3.107 | 3.310 | 3.922 |
| | 1000 | 0.675 | 1.282 | 1.646 | 1.962 | 2.330 | 2.581 | 2.813 | 3.098 | 3.300 | 3.906 |
| | infini | 0.674 | 1.282 | 1.645 | 1.960 | 2.326 | 2.576 | 2.807 | 3.090 | 3.291 | 3.891 |

avec t le test de Student lu dans la table de la loi de Student (Tableau 1) pour v = n-1 et 1-P le risque d'erreur pour lequel on souhaite calculer l'intervalle de confiance (généralement 5%).

Tableau 1 : Table de la loi de Student.

À partir de cette méthode, (A Mangin 1975) a calculé pour différentes valeurs de n le seuil à partir duquel la corrélation peut être considérée comme égale à o (aux seuils de 1% et 5%). Le tableau suivant récapitule ces valeurs.

| La valeur de n = 0,2 prise dans cette thèse correspond à un échantillon de données d'un peu plu | IS |
|---|----|
| de 300 jours, c'est-à-dire pratiquement une année de données. | |

| n | Seuil 5% | Seuil 1% |
|-----|----------|----------|
| 3 | 0,992 | 0,997 |
| 6 | 0,979 | 0,991 |
| 7 | 0,961 | 0,981 |
| 8 | 0,943 | 0,969 |
| 9 | 0,926 | 0,955 |
| 10 | 0,903 | 0,941 |
| 11 | 0,883 | 0,926 |
| 12 | 0,864 | 0,912 |
| 13 | 0,846 | 0,898 |
| 14 | 0,828 | 0,883 |
| 15 | 0,811 | 0,869 |
| 16 | 0,797 | 0,854 |
| 17 | 0,792 | 0,843 |
| 18 | 0,766 | 0,828 |
| 19 | 0,754 | 0,818 |
| 20 | 0,741 | 0,804 |
| 25 | 0,684 | 0,750 |
| 30 | 0,638 | 0,705 |
| 35 | 0,600 | 0,667 |
| 40 | 0,568 | 0,634 |
| 45 | 0,541 | 0,606 |
| 50 | 0,518 | 0,580 |
| 60 | 0,477 | 0,539 |
| 70 | 0,445 | 0,505 |
| 80 | 0,419 | 0,476 |
| 90 | 0,397 | 0,449 |
| 100 | 0,378 | 0,429 |
| 125 | 0,341 | 0,391 |
| 150 | 0,313 | 0,359 |
| 200 | 0,272 | 0,314 |
| 250 | 0,244 | 0,290 |
| 300 | 0,223 | 0,258 |

 Tableau 2 : Valeurs critiques du coefficient de corrélation au risque de 5% d'après A. Mangin (1975)

Annexe B : Méthode de Levenberg-Marquardt

La méthode de Levenberg-Marquard est utilisée pour effectuer l'apprentissage du réseau de neurones par minimisation de la fonction de coût. Elle est basée sur la méthode de descente du gradient de second ordre et utilise une approximation de la matrice hessienne qui ne dépend que des dérivées premières.

La fonction de coût à minimiser est la fonction des moindres carrés, rappelée ci-dessous :

$$J(w) = \sum_{k=1}^{N} \left[y^{k} - y(x^{k}, w) \right]^{2} = \sum_{k=1}^{N} J^{k}(w)$$

où $J^{k}(w)$ est la fonction de coût partielle dépendant des paramètres w et calculée pour un seul exemple k, $y(x^{k}, w)$ est la sortie du modèle pour les variables x^{k} , et y^{k} la sortie désirée (mesure).

La première étape est de calculer le gradient de la fonction de coût à minimiser, ensuite il faut calculer l'incrément à appliquer aux paramètres pour se rapprocher du minimum de cette fonction de coût.

a) Gradient de la fonction de coût

Le gradient de la fonction de coût est calculé à partir des dérivées première, elles mêmes calculées grâce à l'algorithme de la rétropopagation en deux étapes :

- La propagation : le réseau calcule les potentiels et les sorties de tous les neurones pour les exemples qui lui sont successivement présentés.
- La rétropropagation : les dérivées premières de la fonction de coût partielle J^k(w) sont calculées en partant du neurone de sortie vers les entrées pour l'exemple k:

$$\frac{\delta J^k(\boldsymbol{w})}{\delta w_{ij}} = r_i^k . \, s_j^k$$

avec w_{ij} le paramètre reliant le neurone j au neurone i, s_j^k la sortie du neurone j après la présentation de l'exemple k, et pour les paramètres liés au neurone de sortie i:

$$r_i^k = -2[y^k - y(\boldsymbol{x}^k, \boldsymbol{w})] \cdot \left(\frac{\partial s_i}{\partial v_i}\right)_{v_i = v_i^k}$$

Pour les paramètres d'entrée des neurones cachés (l'entrée d'indice *i* est notée s_i comme la sortie d'un neurone du réseau) :

$$r_i^k = \sum_h r_h^k w_{hi} \cdot \left(\frac{\partial s_i}{\partial v_i}\right)_{v_i = v_i^k}$$

où h est l'indice des neurones sur lesquels agit l'entrée i

Les dérivées partielles ainsi obtenues pour chaque exemple *k* permettent de calculer les dérivées partielles que l'on cherche, issues de la présentation des *N* exemples de l'ensemble d'apprentissage :

$$\frac{\delta J(\mathbf{w})}{\delta w_{ij}} = \sum_{k=1}^{N} \frac{\delta J^k(\mathbf{w})}{\delta w_{ij}}$$

b) Modification des paramètres

Le calcul des paramètres à la présentation *i*+1 de l'ensemble de la base de données est effectué de la manière suivante :

$$\mathbf{w}^{i+1} = \mathbf{w}^i - \left[\mathbf{\breve{H}}(\mathbf{w}^i) + \lambda_{i+1}\mathbf{I}\right]^{-1} \nabla J \mathbf{w}^i$$

avec I la matrice identité, λ_{i+1} un paramètre choisi par l'utilisateur et permettant le bon conditionnement de la matrice au commencement de l'algorithme et $\mathbf{H}(w^i)$ l'approximation du Hessien **H** de la fonction de coût $J(w^i)$ à l'itération *i*.

Le Hessien correspond à l'équation suivante :

$$\mathbf{H}(\mathbf{w}^{(i)}) = \sum_{k=1}^{N} \left(\frac{\delta J(\mathbf{w}^{(i)})}{\delta \mathbf{w}}\right) \cdot \left(\frac{\delta J(\mathbf{w}^{(i)})}{\delta \mathbf{w}}\right)^{T} + \sum_{k=1}^{N} \left[\frac{\delta^{2} J(\mathbf{w}^{(i)})}{\delta \mathbf{w} \delta \mathbf{w}^{T}}\right] J(\mathbf{w}^{(i)})$$

La règle de Levenberg-Marquardt permet de calculer l'approximation du Hessien **H** sans recourir au calcul des nombreuses dérivées secondes (p^2 dérivées secondes s'il y a p paramètres), en supposant que terme $\sum_{k=1}^{N} \left[\frac{\delta^2 J(\mathbf{w}^{(i)})}{\delta \mathbf{w} \delta \mathbf{w}^T} \right] J(\mathbf{w}^{(i)})$ est négligeable. Il est alors possible de calculer chacun des termes du Hessien à partir des seules dérivées premières dont les expressions sont données au 1. de cette annexe :

$$h_{ij,lm}(\mathbf{w}^{i}) = \frac{\delta J(\mathbf{w}^{(i)})}{\delta w_{ij}} \cdot \frac{\delta J(\mathbf{w}^{(i)})}{\delta w_{lm}}$$

où *ij* et *lm* sont les indices de la matrice du gradient de la fonction de coût $\left(\frac{\delta J(\mathbf{w}^{(i)})}{\delta \mathbf{w}}\right)^T$.

Annexe C : Modélisation hydrodynamique des karsts par réseaux de neurones: comment dépasser la boîte noire ?

Line Kong A Siou (1,2), Kévin Cros (1), Anne Johannet (1), Valérie Borrell Estupina (2), Séverin Pistre (2).

(1) Ecole des Mines d'Alès, CMGD, 6 avenue de Clavières, 30319 Alès Cedex, France

(2) Université Montpellier II, Hydrosciences Montpellier, Place E. Bataillon, 34095 Montpellier Cedex 5, France

Résumé

Cet article propose d'appliquer un modèle par réseau de neurones pour l'identification de la relation pluie débit d'un système karstique. Le réseau est construit selon l'approche par « boîtes transparentes » de manière à représenter différentes zones au sein même du bassin d'alimentation de la source. Cette architecture particulière permet de contraindre le réseau de neurones vers une solution physiquement interprétable. Les poids attribués à chaque entrée (pluie) du réseau au cours de la phase d'apprentissage sont interprétés en termes de contribution de chaque zone au débit final. De la même façon, les temps de réponse des zones peuvent être approchés. La méthode a été validée en utilisant un bassin d'alimentation virtuel dont on contrôle les paramètres. Le débit généré par ce bassin virtuel a permis d'identifier la relation virtuelle « pluie-débit » par un réseau de neurones permettant ainsi de vérifier que les paramètres du bassin virtuel ont bien été identifiés par le réseau de neurones. Enfin, cette méthode a été appliquée au bassin karstique du Lez et a donné des résultats satisfaisants permettant d'affiner la connaissance du bassin d'alimentation en particulier pour son fonctionnement en hautes eaux.

1. Introduction

Depuis les années 1990 les réseaux de neurones sont utilisés avec succès pour identifier la relation pluie-débit de systèmes hydrologiques variés. Cependant, si ces résultats sont appréciables dans l'optique d'une prévision des crues, ils ne permettent pas de mieux appréhender le système karstique en tant que tel. C'est pourquoi il est proposé dans cet article d'intégrer des connaissances *a priori* dans l'architecture du réseau de neurones afin de le contraindre à donner une solution physiquement acceptable : il s'agit des « boîtes transparentes ». La méthodologie proposée permet d'identifier les contributions et les temps de réponse de différentes zones, ou entités géologiques, au sein d'un même système. Elle a été validée au moyen d'un bassin d'alimentation dit « virtuel » issu d'un modèle de bassin dont les paramètres sont parfaitement contrôlés. Enfin, cette démarche a été appliquée au bassin karstique du Lez (Montpellier, Hérault).

2. Modèle par réseaux de neurones

Les réseaux de neurones sont des modèles non linéaires conçus par apprentissage statistique. Ils sont fondés sur la fonction *neurone* qui est un opérateur mathématique calculant son potentiel, c'est-à-dire la somme pondérée de ses entrées par ses paramètres, puis qui applique à ce

potentiel une fonction d'activation, généralement non-linéaire, pour délivrer la valeur de sa sortie. Les opérateurs neurones sont organisés en *réseau*. Parmi tous les réseaux de neurones proposés, le réseau choisi pour ce travail est un *perceptron multicouche* qui a la propriété d'*approximation universelle*. Le perceptron multicouche, ou approximateur universel, comporte une première couche de neurones non linéaires, dite cachée car ses neurones ne constituent pas une sortie du réseau. La couche de sortie est composée d'un seul neurone linéaire (sa fonction d'activation est la fonction identité). L'identificateur universel, qui est non linéaire en ses paramètres, possède également la propriété de parcimonie vis-à-vis d'autres modèles statistiques linéaires en leurs paramètres. Lorsque l'on utilise l'approximateur universel pour identifier la relation pluie-débit, les variables d'entrées sont constituées d'un historique de pluie (brute ou efficace) par le biais d'une fenêtre temporelle de pluie dont la longueur doit être optimisée (Fig. 1). La sortie du réseau peut représenter la hauteur d'eau ou le débit. La complexité du réseau (le nombre de neurones cachés et la dimension du vecteur des variables d'entrée) doit être ajustée avec rigueur afin de préserver les capacités du modèle à *généraliser*, c'est à dire à effectuer des estimations correctes sur un ensemble de données jamais rencontrées (KONG A SIOU et al. 2011).



Fig. 1 : Perceptron multicouche avec N_c le nombre de neurones cachés, w la longueur de la fenêtre temporelle, r(T) la pluie mesurée au temps T, q(T) le débit calculé au temps T et $q_{observé}(T-1)$ le débit mesuré au temps T-1. S est le neurone de sortie du réseau

Le calcul des paramètres du modèle, appelé l'*apprentissage* est fait par une méthode itérative de minimisation d'une fonction de coût, ici l'erreur quadratique moyenne entre le débit observé et le débit simulé. L'algorithme utilisé est celui de Levenberg-Marquardt (<u>HAGAN et MENHAJ</u>, 1994). Afin d'éviter le « surapprentissage », l'arrêt précoce est utilisé ; cette méthode consiste à arrêter l'apprentissage avant la convergence complète de façon à conserver de bonnes capacités de généralisation. Le lecteur pourra se référer à Dreyfus *et al.* (2008) pour tous les aspects relatifs aux réseaux de neurones et à Govindaraju (2000) pour les applications nombreuses en hydrologie.

3. Bassin karstique du Lez

L'aquifère du Lez est très étudié depuis une cinquantaine d'années du fait de son exploitation pour la ressource en eau potable (dorfliger *et al.* 2008). Depuis 1982, l'exploitation de la source du Lez, via des forages atteignant directement le drain principal de la source, assèche prématurément celle-ci et les sources temporaires, exutoires de l'aquifère. Un débit restitué, imposé par Déclaration d'Utilité Publique, s'ajoute au débit qui s'écoule naturellement de la source. Les débits mesurés sont donc en partie artificiels.

De plus, à la nature karstique de l'aquifère s'ajoute une forte hétérogénéité géologique (Fig. 2). Les failles jouent un rôle prépondérant : tantôt drain, tantôt barrière selon les formations qu'elles mettent en contact, faisant ainsi apparaître plusieurs compartiments au sein de l'aquifère (Thiery *et al.* 1983). Pour cette étude, le bassin d'alimentation a été découpé en quatre zones qui seront par la suite considérées comme géologiquement homogènes. Apparaissant en traits noirs sur la

carte (Fig. 2), ces zones se décomposent en : la zone Sud-Ouest qui correspond à la plus grande zone d'affleurement de l'aquifère principal, et donc à la principale zone de recharge directe. Elle est cependant séparée de la source par la faille de Corconne qui met en contact l'aquifère avec des calcaires marneux imperméables (Fig. 2). Les échanges entre l'ouest et l'est de la faille sont donc perturbés. Par ailleurs ce secteur est également drainé, en hautes eaux, par la source du Lirou qui apparaît à la faveur de la faille précitée et dont le débit avoisine celui de la source du Lez en période de crue. Dans la zone Sud Est, le karst est complètement sous couverture de marnes, de brèches et de conglomérats. Cette zone correspond cependant à une partie de la zone d'influence du pompage de la source du Lez (Thiery *et al.* 1983).



Fig. 2 : Carte géologique simplifiée du bassin d'alimentation de la source du Lez

La zone Nord-Ouest est essentiellement sous couverture et comprend une partie de l'aquifère perché du Causse de l'Hortus. Cet aquifère karstique, situé au-dessus de l'aquifère principal, est supposé déconnecté de celui-ci par des marnes et calcaires marneux. L'infiltration de l'eau dans cet aquifère ne pourra donc contribuer directement à la recharge de l'aquifère principal. En revanche, les différentes sources aux abords du Causse de l'Hortus donnent naissance à des cours d'eau qui se perdent, notamment au niveau de la faille de Corconne, participant ainsi indirectement à la recharge de l'aquifère du Lez. Enfin, la zone Nord-Est est partiellement sous-couverture avec des affleurements peu étendus du karst. Les failles constituent un axe de drainage important vers la source, ainsi que le montrent de nombreuses études sur le site du Terrieu situé dans cette zone, la plus récente étant celle de jazayeri noushabadi (2009), et des expériences de colorations (marjolet & salado 1976).

Les données utilisées dans cette étude sont les débits journaliers mesurés à la source du Lez et les cumuls de pluies journalières mesurées par les six postes pluviométriques présentés sur la carte en Figure 2. Grâce à la méthode des polygones de Thiessen, l'influence de chaque pluviomètre est approchée. L'intersection de ces polygones, avec les zones géologiques, permet de générer les séries chronologiques de pluies correspondant à chaque zone géologique. La pluie sur une zone donnée correspond ainsi à la somme des pluies mesurées par les pluviomètres influant sur cette zone, pondérée par le pourcentage de la surface occupée par chaque polygone de Thiessen correspondant à chaque pluviomètre.

4. Méthode des « boîtes transparentes »

Fruits d'une première étape nécessaire, les résultats d'un modèle de type *boîte noire* par réseau de neurones dédié au bassin karstique du Lez montrent que la relation pluie débit peut être efficacement simulée avec des coefficients de Nash supérieur à 0,90 (KONG A SIOU et al. 2010).

La méthode des *boîtes transparentes* (JOHANNET *et al.* 2008b) consiste à introduire des contraintes dans l'architecture du réseau de neurones afin de conduire ce dernier vers un modèle physiquement interprétable. Dans le cas de bassin d'alimentation du Lez, quatre zones géologiquement homogènes ont été distinguées (voir paragraphe 3). Ainsi, la contribution de chacune des entités géologiques est individualisée dans le réseau par un neurone linéaire pour chaque zone. Ceci constitue l'information *a priori* que l'ont peut inclure dans l'architecture du modèle, comme illustré sur la Figure 3.



Fig. 3 : Modèle pluie-débit par réseau de neurones pour un système comportant quatre sous-bassins.

L'objectif de l'étude est d'identifier les contributions de différentes zones, considérées comme autant de sous-bassins, à un exutoire commun, ainsi que les temps de réponse associés.

Un premier paragraphe présente la méthode permettant de d'estimer la contribution d'un sousbassin (grâce à la pluie tombée sur ce sous-bassin) par rapport à la sortie (débit). Néanmoins, comme aucune information mesurée n'existe pour valider l'information des volumes d'eaux issus de chaque sous-bassin et son temps de réponse, le second paragraphe présente un hydrosystème virtuel, qui a été créé afin que la méthode des boîtes transparentes puisse lui être appliquée et ainsi valider son utilisation sur l'aquifère réel.

3.1. Estimation des contributions des sous-bassins

Yacoub & Bennani (1997) ont proposé une méthode de sélection des variables d'entrée basée sur le calcul du *poids* des entrées, et visant à ordonner les entrées en fonction de leur importance dans l'estimation faite par le réseau. Pour ce faire, les poids sont calculés comme suit pour chaque variable *r*(T) (T est le temps discret journalier) connectée à un neurone linéaire i :

$$P\left(r_j(T)\right) = C_i \sum_{n=1}^{N_c} (C_{ni} C_{sn})$$

Avec : $P(r_j(T))$ le poids de l'entrée $r_j(T)$; et C_i , C_{sn} , C_{ni} les valeurs des paramètres (Fig. 4) obtenus à l'issue de l'apprentissage.



Fig. 4: Notation des paramètres pour le calcul du poids des entrées. Les neurones cachés n sont numérotés de 1 à N_c.

Dans cette étude, le calcul des poids n'est pas utilisé pour sélectionner les entrées, mais pour évaluer (i) la contribution de chaque sous-bassin au débit sortant à la source (ii) le temps de réponse du sous-bassin. Pour estimer la contribution de chaque sous-bassin au débit sortant à la source, les poids obtenus pour les variables correspondant à chaque jour de la fenêtre temporelle de pluie d'un sous-bassin sont additionnés et représentent alors la contribution du sous-bassin correspondant. Les contributions de chaque sous-bassin et du débit observé en entrée du réseau sont ensuite ramenées en pourcentages pour être comparées et estimer la contribution de chaque sous-bassin au débit total. Pour estimer le temps de réponse du sous-bassin considéré, les valeurs des poids de chaque jour de pluie sont comparées pour un même sous-bassin : le jour de pluie qui a le poids le plus important correspond au temps de réponse du sous-bassin correspondant.

3.2. Validation de la méthode

L'hydrosystème virtuel composé pour valider la méthode des boîtes transparentes comporte quatre sous-bassins avec des propriétés différentes (réservoirs linéaires ou non, temps de réponse variant de deux à six jours, contributions à l'exutoire de 8% à 37%). Chaque sous-bassin est alimenté par une pluie choisie comme égale à une pluie réelle mesurée par l'un des pluviomètres du bassin du Lez. Ceci est important car les pluies journalières ont une corrélation mutuelle assez forte (> 0,7).

Les quatre sous-bassins alimentent des réservoirs, qui eux-mêmes alimentent des canaux. Chaque canal introduit un temps de retard et un pourcentage de pertes qui permettent de régler les contributions et les temps de réponse des sous-bassins. Le débit en sortie du bassin virtuel est la somme des débits sortant des canaux. Le bassin virtuel a été généré avec le logiciel HEC-HMS (US Army Corps of Engineers). Quatre chroniques de « débit virtuel » ont été générées en faisant varier les temps de retard des sous-bassins (expériences I à IV : voir Tabl. 2).

A partir des chroniques de pluies et de débit virtuel, un réseau de neurones a été utilisé en boîte transparente pour identifier la relation « pluies »-« débit virtuel ». Quatre boîtes transparentes sont ainsi réalisées, une pour chaque expérience. Les résultats sont les suivants : les temps de retard sont identifiés sans erreur par le réseau de neurones. Les contributions des différents sous-bassins sont correctement identifiées pour les sous-bassins S₁, S₂ et S₄ qui ont la contribution la plus forte : l'erreur sur leur contribution est au maximum de 18%, et le plus souvent inférieure à 10% (Tabl.1). Le sous-bassin S₁, qui comporte un réservoir non-linéaire, est celui qui globalement comporte les plus faibles erreurs d'estimation de sa contribution. Sa contribution au débit final est proche de celle du sous-bassin S₂ qui lui, a un réservoir linéaire. En revanche, la contribution du sous-bassin ayant le moins d'importance (S₃, 8% du débit final) n'a pas été identifiée correctement (plus de 30% d'erreur en moyenne), sauf dans le cas de l'expérience II où ce sous-bassin a un

| Expériences/sous-bassin | S ₁ | S ₂ | S ₃ | S ₄ |
|-------------------------|----------------|----------------|-----------------------|-------------------|
| 1 | 3 % | 0 % | 43 % | 11 % |
| II | 18 % | 8 % | <u>7 % (4 J.)</u> | 11 % |
| III | 2 % | 16 % | 64 % | <u>9 % (6 J.)</u> |
| IV | 3 % | 5 % | <u>31 % (4 J.)</u> | <u>1 % (6 J.)</u> |

temps de réponse (4 jours) différent de tous les autres (2 jours). La contribution de S_3 est alors identifiée avec 7% d'erreur seulement.

Tabl. 1 : Erreur sur l'estimation de la contribution des sous-bassins S₁ à S₄. Les expériences I à IV font varier les temps de retard qui sont de 2 jours par défaut, et indiqués en gras et entre parenthèses lorsqu'ils varient.

Il faut cependant noter que vu la forte corrélation mutuelle des pluviomètres, cette méthode ne devrait pas permettre de voir si le contour des zones est correct ou non. Il est donc important d'avoir une bonne connaissance *a priori* des sous-bassins à individualiser.

4. Application au bassin karstique du Lez

La méthodologie exposée dans le paragraphe 4. est appliquée au bassin du Lez, découpé en quatre zones géologiques telles que précédemment présenté (Fig. 2). Une première phase de sélection de variables et de la complexité a permis de sélectionner le nombre de jours optimal pour chaque fenêtre temporelle (Tabl. 2), ainsi que le nombre de neurones cachés. Une fois l'apprentissage réalisé, il faut noter que le réseau de neurones a minimisé l'erreur quadratique, le rendant ainsi plus sensible aux débits élevés. Les résultats sont donc à considérer comme reflétant le comportement du système en période de hautes eaux.

La simulation pluie-débit est très bien réalisée avec un coefficient de Nash de 0,96 pour l'année de test qui n'a aucunement servi pour d'apprentissage. Les contributions des différentes entrées sont indiquées sur la Table 2. La contribution totale des pluies atteint 88%, les 12% restants correspondent au débit observé du jour précédent appliqué en entrée du modèle. La zone Sud-Est a un poids très faible, qui s'explique d'une part par sa position en aval de la source et d'autre part par la couverture imperméable qui empêche l'infiltration vers l'aquifère principal dans cette zone. La zone Sud-Ouest a un poids assez faible alors qu'elle est classiquement considérée comme la zone de recharge directe ; cependant cette zone est également drainée, en hautes eaux, par la source du Lirou. La zone Nord-Ouest a un poids assez important, confortant l'hypothèse d'une participation du Causse de l'Hortus via les exsurgences drainant cet aquifère perché. Les cours d'eau prenant naissance en bordure du causse viennent ensuite se perdre au niveau de la faille de Corconne et donc probablement rejoindre l'aquifère principal. Enfin, la zone Nord-Est a le poids le plus fort, expliqué par la présence de nombreuses failles dirigées vers la source du Lez et qui peuvent permettre à la fois l'infiltration et le drainage.

| Sous-bassin | Sud Est | Sud Ouest | Nord Ouest | Nord Est |
|-----------------|---------|-----------|------------|----------|
| Nombre de jours | 1 | 8 | 10 | 12 |
| Contribution | 5% | 11% | 28% | 44% |

Tabl. 2 : Contribution au débit à la source et nombre de jours d'historique de pluie pour chaque sous-bassin réel.

L'étape suivante consiste à regarder individuellement les poids des entrées pour les différents jours de l'historique de pluie. Ces poids sont représentés sur la Figure 4.



Fig. 4 : Poids de chaque jour de l'historique de pluie pour les différentes zones géologiques

La zone Sud Est ne comportant qu'un seul jour de pluie, elle n'est représentée que par son poids au jour o (jour de la simulation). Pour les autres zones, on constate un pic au jour 1, qui signifie que c'est la pluie tombée le jour précédent qui est la plus influente pour la simulation du débit. La zone Nord-Ouest se démarque par des valeurs élevées jusqu'à trois jours, ce qui conforte l'hypothèse d'une infiltration retardée par un passage dans l'aquifère perché du Causse de l'Hortus comme cela a été mentionné précédemment. La zone Sud-Est qui a une contribution très minoritaire peut vraisemblablement être partiellement exclue du bassin d'alimentation de la source du Lez, au moins pour le comportement en hautes eaux.

5. Conclusion

La méthode présentée dans cet article permet (i) de simuler efficacement le débit à partir de chroniques de pluies et de débits observés, (ii) d'approcher des grandeurs physiquement interprétables (temps de réponse du système, contribution de sous-bassins d'alimentation). La méthode est générique et applicable à tout système dont on connaît les informations de pluie et de débit. Appliquée au bassin karstique du Lez, cette méthode a donné des résultats satisfaisants et permis d'approfondir la connaissance du bassin d'alimentation.

Références

- 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.
- DREYFUS G., SAMUELIDES M., MARTINEZ J.-M., GORDON M.-B., BADRAN F., THIRIA S., HÉRAULT L. 2008. Apprentissage statistique. Eyrolles. 450p.
- Govindaraju R.S. 2000. Artificial neural networks in hydrology. I: Preliminary concepts. J. of Hydrol. Engineering, 5(2): 115-123.
- Jazayeri Noushabadi M.R. 2009. Characterisation of relationship between fracture network and flow-path network in fractured and karstic reservoirs. Thèse Montpellier. 326p.
- Johannet A., Vayssade B. & Bertin, D. 2008. Neural Networks: From Black Box towards Transparent Box Application to Evapotranspiration Modeling. Int. J. of Computational Intelligence 4(3).

- Hagan, M.T. & M.B. Menhaj. (1994), Training feedforward networks with the Marquardt algorithm, *Neural Networks* 5(6), 989-993.
- KONG A SIOU L., JOHANNET A., PISTRE S., & BORRELL V. 2010. Flash floods forecasting in a karstic basin using neural networks: the case of the *Lez* karstic basin (south of France). In *Advances in research in karst media*: 215-221
- 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). J. of Hydrology 403 (3-4)
- Marjolet G. & Salado J. 1976. Contribution à l'étude de l'aquifère karstique de la source du Lez (Hérault). Thèse Montpellier C.E.R.H.
- Thiery D., Bérard P., & Camus A. 1983. Captage de la source du Lez. Etude de relation entre la source et son réservoir aquifère rapports n°1 et 2.
- Yacoub & Bennani. 1997. A heuristic for variable selection in multilayer artificial neural network classifier. Intelligent Engineering Systems Through Artificial Neural Networks 7: 527-532.