



Les réseaux de neurones artificiels pour la modélisation hydrodynamique des aquifères karstiques.

A. Johannet, Virgile Taver, Line Kong a Siou, Valérie Borrell Estupina, S. Pistre, Alain Mangin, Bernard Vayssade, M. Vinches, Dominique Bertin

► To cite this version:

A. Johannet, Virgile Taver, Line Kong a Siou, Valérie Borrell Estupina, S. Pistre, et al.. Les réseaux de neurones artificiels pour la modélisation hydrodynamique des aquifères karstiques.. Karstologia, 2014, 60, pp.45-59. <10.3406/karst.2012.2728>. <hal-02047988>

HAL Id: hal-02047988

<https://hal.science/hal-02047988v1>

Submitted on 26 May 2021

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.



Distributed under a Creative Commons CC BY 4.0 - Attribution - International License

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

Anne Johannet, Virgile Taver, Line Kong-A-Siou, Valérie Borrell, Severin Pistre, Alain Mangin, Bernard Vayssade, Marc Vinches, Dominique Bertin

Citer ce document / Cite this document :

Johannet Anne, Taver Virgile, Kong-A-Siou Line, Borrell Valérie, Pistre Severin, Mangin Alain, Vayssade Bernard, Vinches Marc, Bertin Dominique. Les réseaux de neurones artificiels pour la modélisation hydrodynamique des aquifères karstiques : présentation générale et illustrations. In: Karstologia : revue de karstologie et de spéléologie physique, n°60, 2e semestre 2012. Dynamique sédimentaire dans le siphon de Chevaline. pp. 45-59;

doi : <https://doi.org/10.3406/karst.2012.2728>

https://www.persee.fr/doc/karst_0751-7688_2012_num_60_1_2728

Fichier pdf généré le 15/03/2019

Résumé

Les aquifères karstiques permettent d'alimenter en eau potable près de 25 % de la population mondiale. Sur le pourtour méditerranéen, ils sont considérés parfois comme des châteaux d'eau naturels ou bien comme des barrages écrêteurs de crue. Ces propriétés remarquables, stimulantes par les enjeux soulevés sont cependant difficiles à quantifier et à appréhender objectivement du fait de la complexité du karst, due à une forte hétérogénéité de structure induisant également des non-linéarités. Dans ce contexte cet article propose d'aborder la modélisation hydrodynamique des karsts par une nouvelle approche appartenant à l'apprentissage statistique : les réseaux de neurones artificiels. Ces derniers sont des modèles mathématiques issus de l'intelligence artificielle qui peuvent identifier toute fonction dynamique non linéaire au moyen d'un apprentissage. Ils sont ainsi parfaitement à même de modéliser les fonctions inconnues des aquifères karstiques pourvu que l'on dispose d'une base de données. Très utilisés en hydrologie et appliqués également à la modélisation hydrodynamique des aquifères karstiques, les réseaux de neurones sont tout d'abord abordés dans cet article pour effectuer des fonctions de prévision des crues ou de simulation de débit. Leur capacité d'apprentissage est présentée dans le cadre du paradigme systémique, non seulement pour réaliser la fonction de boîte noire, mais également pour améliorer la connaissance des aquifères karstiques. Ainsi, l'origine des eaux et les temps de transferts peuvent être mieux appréhendés grâce à une méthodologie originale. Cet article présente les études menées sur deux bassins karstiques bien connus, et disposant de nombreuses données de pluie et de débit : le Baget (Ariège) et le Lez (Hérault).

Abstract

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

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

Anne JOHANNET¹,
Virgile TAVER¹⁻²,
Line KONG-A-SIOU³,
Valérie BORRELL ESTUPINA²,
Séverin PISTRE²,
Alain MANGIN⁴,
Bernard VAYSSADE¹,
Marc VINCHES¹ et
Dominique BERTIN⁵

(1) Ecole des Mines d'Alès, LGEI,
6, av. de Clavières, 30319 Alès Cedex,
France, a.johannet@mines-ales.fr

(2) UM2 - Hydrosiences,
2, place Eugène Bataillon,
34095 Montpellier Cedex 5, France

(3) ENSEGI, 1, allée François Daguin,
33607 Pessac, France

(4) Station d'Écologie Expérimentale,
09200 Saint-Girons, France

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

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

RÉSUMÉ : Les aquifères karstiques permettent d'alimenter en eau potable près de 25 % de la population mondiale. Sur le pourtour méditerranéen, ils sont considérés parfois comme des châteaux d'eau naturels ou bien comme des barrages écrêteurs de crue. Ces propriétés remarquables, stimulantes par les enjeux soulevés sont cependant difficiles à quantifier et à appréhender objectivement du fait de la complexité du karst, due à une forte hétérogénéité de structure induisant également des non-linéarités. Dans ce contexte cet article propose d'aborder la modélisation hydrodynamique des karsts par une nouvelle approche appartenant à l'apprentissage statistique : les réseaux de neurones artificiels. Ces derniers sont des modèles mathématiques issus de l'intelligence artificielle qui peuvent identifier toute fonction dynamique non linéaire au moyen d'un apprentissage. Ils sont ainsi parfaitement à même de modéliser les fonctions inconnues des aquifères karstiques pourvu que l'on dispose d'une base de données. Très utilisés en hydrologie et appliqués également à la modélisation hydrodynamique des aquifères karstiques,

les réseaux de neurones sont tout d'abord abordés dans cet article pour effectuer des fonctions de prévision des crues ou de simulation de débit. Leur capacité d'apprentissage est présentée dans le cadre du paradigme systémique, non seulement pour réaliser la fonction de boîte noire, mais également pour améliorer la connaissance des aquifères karstiques. Ainsi, l'origine des eaux et les temps de transferts peuvent être mieux appréhendés grâce à une méthodologie originale. Cet article présente les études menées sur deux bassins karstiques bien connus, et disposant de nombreuses données de pluie et de débit : le Baget (Ariège) et le Lez (Hérault).
MOTS-CLÉS : karst, modélisation hydrodynamique, réseaux de neurones, apprentissage statistique, KnoX.

ABSTRACT: ARTIFICIAL NEURAL NETWORKS FOR HYDRODYNAMIC MODELING OF KARST AQUIFERS: OVERVIEW AND ILLUSTRATIONS. Karst aquifers provide fresh water for about 25 % of the global population. Around the Mediterranean Sea, they are sometimes considered as natural water castles or as dams, able to minimize floodings. The high level of heterogeneity

found in such aquifers and the difficulties encountered in delimiting their subterranean catchment area make it a challenge to fully understand their hydrological behavior, and accurately simulate and forecast their evolution. In this context, this article presents how hydrodynamic modeling of karst aquifers can be usefully performed using a new approach issued from machine learning: neural networks. Thanks to an automatic way to calculate their parameters, called learning, neural networks can model unknown functions using a representative database. Increasingly used in hydrology, neural networks are first introduced in this article to perform discharge simulation and flood forecasting. The training ability of neural networks is given in the framework of the systemic paradigm, not only restricted to black box modeling, but also to increase information related to the basin behavior (time transfer and water origin). Illustrations are provided on two well-known French karst basins: the Baget (Ariège) and the Lez (Hérault), both associated with extensive datasets.

KEYWORDS: karst, hydrodynamic modeling, neural networks, machine learning, KnoX.

Introduction : l'apprentissage statistique pour la modélisation hydrodynamique

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

Comme énoncé par John Von Neumann, le père de l'ordinateur qui

imagina nombre de leurs applications dans les années 1940, une des difficultés de la conception de systèmes modélisant les milieux naturels est la complexité extrême de ces systèmes, qui nous paraissent pourtant parfois si simples. Si l'on se risquait à vouloir décrire complètement et exhaustivement toutes les situations que peut rencontrer un bassin versant, ceci nous amènerait à lister et expliciter toutes les fonctions de ce

système. Il apparaîtrait assez rapidement que cette tâche dépasserait les capacités humaines. L'approche algorithmique qui a nourri les systèmes experts à leurs débuts a ainsi montré ses limites, non seulement parce que toutes les configurations possibles ne peuvent être décrites, car elles sont trop nombreuses, mais également parce que l'information utile n'est pas forcément disponible sous une forme accessible par des mesures.

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

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

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

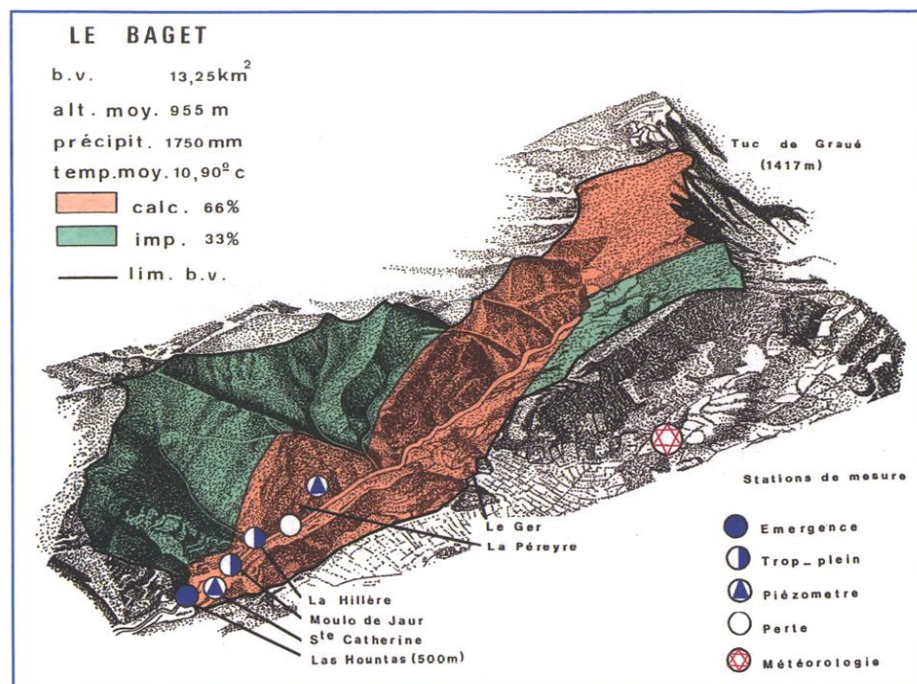


Figure 1: Bassin versant du Baget [d'après Rouch, 1982]. The catchment area of Baget.

Sachant qu'une partie du lectorat de *Karstologia* n'est pas familiarisée avec une approche très formelle, nous demanderons à ces lecteurs de bien vouloir se laisser entraîner sans a priori dans la lecture de cet article que nous allons tenter de rendre accessible à tous les publics curieux intéressés. Après la présentation, dans la section II, des deux bassins supports de nos modélisations : les bassins du Lez dans l'Hérault et du Baget en Ariège, nous vous proposons d'enchaîner la lecture par la présentation du dilemme biais-variance, que l'on peut entendre comme une formulation statistique du *principe du rasoir d'Occam*¹, et qui conduit à sélectionner le modèle neuronal de complexité minimale afin d'assurer une bonne qualité de généralisation. Créer un modèle trop complexe, section IV avec trop de paramètres conduit à une facilité d'apprentissage accrue, dont la contrepartie est une difficulté de généralisation pour le modèle : ce dernier n'est plus capable de généraliser à des fonctionnements nouveaux car il s'est spécialisé à outrance sur ses données d'apprentissage. Nous avons pensé utile d'illustrer le piège du biais-variance, conduisant au surajustement, sur la modélisation de la relation pluie-débit par des modèles neuronaux. Nous aurons donc l'occasion d'observer la manifestation théorique de ce surajus-

tement par l'augmentation de la variance du modèle de simulation calculé sur le Baget, lorsque l'on augmente le nombre de paramètres. Sur le modèle du Lez, nous pourrions observer, en pratique, une des manifestations caractéristiques de ce surajustement. Enfin, nous pourrions alors présenter les modèles de prédicteur les plus adaptés à la modélisation des systèmes karstiques, qui nous intéressent particulièrement dans cet article.

Hétérogènes par nature, les bassins karstiques n'ont rien de ce qui rend belle la physique : l'invariance d'échelle et la symétrie. Cumulant souvent une géologie complexe et une fracturation dont l'hétérogénéité naturelle est renforcée par la karstification, les systèmes karstiques, spécialement en montagne ou sur le pourtour méditerranéen, sont de plus soumis à des forçages météorologiques très mal connus et souvent imprévisibles. Alimentant près du quart de la population mondiale en eau douce et considérés comme les châteaux d'eau de la Méditerranée, les aquifères karstiques peuvent jouer à la fois le rôle de soutien d'étiage et de barrage écrêteur de crue. Les enjeux qui leur sont associés sont donc considérables. Deux bassins tests ont été choisis pour illustrer nos travaux sur la modélisation hydrodynamique des aquifères

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

karstiques : le bassin du Baget, situé en Ariège (France) et le bassin du Lez situé dans l'Hérault (France). Tous deux seront présentés en section I de cet article et les travaux de modélisation destinés à prévoir ou simuler leurs crues ainsi que leurs étiages seront présentés en section III.

Disposer de modèles efficaces est évidemment essentiel lorsque l'on travaille sur de tels enjeux, mais *comprendre* ces modèles ou les utiliser pour mieux *connaître* les processus naturels est encore plus passionnant ; c'est le défi évoqué dans la cinquième et dernière partie de cet article. Nous y présentons comment l'on peut esquisser des modèles semi-physiques ou comment, grâce à l'intégration de connaissances dans l'architecture du réseau de neurones, cette dernière peut être contrainte pour, en retour, permettre d'en extraire de l'information. Nos travaux sur le système karstique du Lez, qui cumule les difficultés d'une hétérogénéité géologique, d'une hétérogénéité pluviométrique, d'une anthropisation des débits par un pompage intense et d'un bassin à géométrie variable en fonction du niveau du remplissage, ont permis non seulement d'obtenir un modèle prédictif convenable, mais en plus d'estimer les transits d'eau souterraine entre les différents compartiments du karst et la source.

I. Deux bassins karstiques tests : le Baget et le Lez

A. Le Baget

Le karst du Baget est un karst pyrénéen bien connu [Mangin 1970] et pour lequel nous disposons d'une base de mesures importante. Le bassin du Baget (Ariège) a une superficie de 13,25 km² et comporte environ 1/3 de superficie non calcaire. C'est un karst d'altitude moyenne 950 m et de pluviométrie importante : plus de 1 500 mm d'eau en moyenne annuelle sur la période d'étude (1973 à 2000), avec une évapotranspiration annuelle estimée à 540 mm. Le ruisseau du Baget (photo 1), comme la plupart de ses homologues pyrénéens, a un étiage prononcé en automne et des crues importantes en décembre et au printemps. Compte tenu de l'altitude moyenne, le stockage d'eau sous forme de neige est assez faible et la fonte des neiges ne donne pas lieu à des crues importantes.

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

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

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

B. Le Lez

Le karst du Lez (Hérault) est un aquifère méditerranéen très étudié depuis les années 1970 [Marjolet et Salado, 1976 ; Paloc, 1979], du fait de l'important réservoir en eau qu'il représente et de la proximité de la ville de Montpellier, qui connaissait à l'époque une croissance démographique forte.



Photo 1 : Ruisseau du Baget en aval de Las Hounta. Cliché Anne Johannet. *The Baget brook downstream of Las Hountas spring.*

L'exutoire principal de ce karst, la source du Lez (photo 2), est exploité par pompage directement dans le drain karstique depuis 1982, ce qui a pour effet d'assécher la source en période d'étiage. Une Déclaration d'Utilité Publique impose un débit de pompage maximum de 1 700 l/s et un rabattement maximum de 30 m dans le piézomètre proche du pompage. Enfin, le débit réservé minimum est de 160 l/s dans la rivière. Ainsi, lorsque la source est à sec, un débit de 160 l/s minimum est restitué à la rivière. Le débit de la source du Lez est mesuré en aval de cette restitution. Le débit mesuré est donc la somme du débit naturel et du débit restitué. Une telle exploitation est rendue possible




Photo 2 : Source du Lez. Cliché Bernard Vayssade. *The Lez spring.*

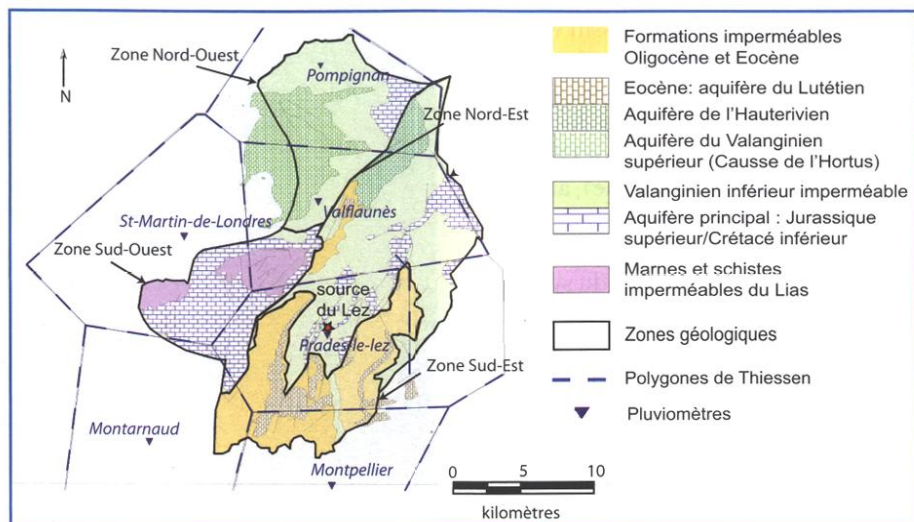


Figure 2: Bassin hydrogéologique de la source du Lez [Kong-A-Siou, 2011] : zones géologiques, pluviomètres et polygones de Thiessen. The hydrogeological catchment of Lez spring: Geological zonation, rain gauges and Thiessen polygons.

par la spécificité du climat méditerranéen, très sec en été, mais très humide à l'automne (40 % des précipitations annuelles tombent entre septembre et novembre). Les pluies intenses d'automne permettent donc la recharge de l'aquifère qui a été surexploité durant l'été. La recharge ainsi effectuée permet, de plus, de mitiger les crues d'automne [Borrell-Estupina et al., 2014; Fleury et al., 2011].

Le bassin hydrogéologique de la source du Lez est estimé à 400 km² environ [Fleury et al., 2008]. Ces limites de bassins (figure 2) ont été proposées à partir de la compilation d'études antérieures. L'aquifère principal du Lez est constitué de calcaires d'âge jurassique moyen, il est captif sur une grande partie du bassin et libre au sud-ouest (Causse de Viols-le-Fort). Le bassin comporte également des karsts perchés,

qui ne sont pas en relation directe avec le karst principal. Les niveaux géologiques sont affectés par de nombreuses failles, généralement orientées sud-ouest nord-est. Ces failles ont essentiellement joué en décrochement puis en faille normale, elles constituent une zone d'infiltration et de circulation préférentielle de l'eau. La faille de Corconne qui traverse le bassin du sud-ouest au nord-est peut également faire office de barrage aux écoulements, en particulier dans sa partie sud qui met en relation les terrains karstifiés situés à l'ouest avec des terrains peu perméables situés à l'est (figure 2) [Bérard, 1983; Karam, 1989].

Le système karstique du Lez a été découpé en 4 zones, fondées sur le croisement entre le contexte hydrogéologique connu et les propriétés du bassin de surface [Kong-A-Siou et al., 2011]. Ci-dessous, voici résumées les considé-

rations qui nous ont permis d'aboutir à ce découpage, qui nous sera utile dans la partie IV-b), le lecteur intéressé trouvera de plus amples informations sur l'hydrosystème Lez dans un prochain numéro de *Karstologia*:

- La faille de Corconne apparaît comme une limite évidente entre la partie est et la partie ouest du bassin. Il faut rappeler que cette faille met en relation des niveaux karstifiés avec des niveaux marneux peu perméables ce qui constitue un frein à l'écoulement entre les parties est et ouest du bassin. De plus elle constitue une zone d'infiltration privilégiée grâce à la présence de nombreuses pertes le long de la faille (photo 3).
- La zone d'affleurement des terrains tertiaires au sud du bassin constitue une zone particulière pour l'infiltration car ces terrains sont très peu perméables (conglomérats). L'aquifère est ici captif, recouvert par plusieurs centaines de mètres de terrains dont certains sont très peu perméables.
- Le Causse de Viols-le-Fort, où affleurent presque exclusivement les terrains aquifères est également identifié comme une zone homogène en termes de recharge de l'aquifère principal. L'infiltration se fait directement dans les calcaires du jurassique qui présentent une karstification bien développée sur le Causse. Cette zone constitue donc une zone d'infiltration, délimitée à l'est par la faille de Corconne et au nord par le ruisseau du Terrieu.
- Enfin, le Causse de l'Hortus, aquifère perché séparé de l'aquifère principal par les marnes du Valanginien (Crétacé supérieur) constitue la dernière zone. La limite est correspond à la faille de Corconne et la limite sud au ruisseau du Terrieu (photo 4).

Photo 3: Perte dans le Brestalou de Claret au niveau de la faille de Corconne. Cliché Anne Johannet. Swallow-hole in the Brestalou de Claret, at the Corconne fault.



II. Les réseaux de neurones formels

A. Définitions

1. Apprentissage

L'apprentissage consiste à estimer le vecteur θ des paramètres des fonctions paramétrées (appelées neurones) du réseau de neurones afin de minimiser un critère préalablement défini. Ce critère, encore appelé *fonction de coût*, est généralement l'erreur quadratique moyenne. Comme le modèle neuronal est non linéaire en ses paramètres, la *fonction de coût* n'est pas quadratique en

ses paramètres et la méthode des moindres carrés n'est donc pas applicable. Des méthodes de minimisation itératives de la fonction de coût sont donc utilisées. Le lecteur intéressé pourra trouver de plus amples informations sur les méthodes de calcul itératives des paramètres, appelées *règles d'apprentissage*, dans Dreyfus et al. [2008] ; il suffit d'indiquer ici que la règle la plus efficace est actuellement la règle de Levenberg-Marquardt, que nous avons utilisée dans tous nos travaux récents, qui est une règle de gradient du second ordre faisant appel à l'inversion d'une matrice approchée de la matrice Hessienne [Bender et al., 1996 ; Press et al., 1992]. Cette méthode est avantageuse car bien qu'appartenant à la catégorie des méthodes de second ordre, elle ne nécessite pas le calcul des dérivées secondes de la fonction de coût.

2. Modèles de neurones et architectures

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

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

Le neurone formel effectue deux actions :

- le calcul de son potentiel v , ou somme pondérée de ses variables d'entrée par ses paramètres : $v = x \cdot \theta$;
- le calcul de sa sortie y par une fonction d'évaluation qui est non linéaire ou parfois linéaire : $f(\cdot)$.

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

Grâce aux modèles de neurones précédemment définis, un réseau de neurones peut être conçu en connectant les neurones les uns aux autres grâce à une *architecture*. Parmi toutes les architectures proposées, le réseau appelé *perceptron multicouche* sera particulièrement utilisé ; nous l'appellerons dans la suite plus simplement réseau. Ce réseau est composé d'une couche de neurones non linéaires de type sigmoïde,




Photo 4 : Vue sur le bassin d'alimentation de la source du Lez depuis le Bois de Paris : Pic-Saint-Loup (à gauche) et Causse de l'Hortus (à droite). Cl ché Anne Johannet. *Regard on the catchment area of the Lez spring from the Bois de Paris : Pic-Saint-Loup (left) and Causse de l'Hortus (right).*

dite *couche cachée* car il n'y a pas de grandeur observée correspondant aux sorties de ces neurones, et d'une couche de sortie composée dans nos études d'un seul neurone.

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

3. Identification universelle et parcimonie

K. Hornik et al. ont démontré que le perceptron multicouche possédait la propriété d'approximation universelle [1989]. C'est-à-dire que toute fonction $g(x)$, à valeurs bornées dans un domaine défini, peut être approchée à la précision près dans ce domaine par un réseau de type multicouche possédant un nombre fini de neurones cachés. C'est sur cette propriété que nous fondons le choix d'utiliser le perceptron multi-

couche pour identifier les relations non linéaires des systèmes karstiques que nous étudions. Bien entendu, la capacité à trouver la solution dépendra tout autant de la base des informations disponibles que de la méthode de calcul des paramètres.

Or, la capacité d'identification universelle a son prix, c'est celui de l'augmentation du nombre de paramètres libres du modèle qu'il faut ajuster. Opérant sur des fonctions non linéaires (les fonctions paramétrées neurones), ces paramètres permettent au modèle de s'ajuster parfaitement à l'ensemble d'apprentissage, et d'autant plus efficacement que le nombre de ces paramètres, ou la complexité du modèle, croît. Mais le modèle, si certaines précautions ne sont pas prises, peut alors être *surajusté* et tellement spécialisé par rapport à l'ensemble d'apprentissage qu'il apprendrait même la réalisation particulière du bruit dans cet ensemble et serait alors




Figure 3 : Réseau Perceptron Multicouche, les ronds représentent les neurones, les carrés les variables, les flèches correspondent aux paramètres. *Multilayer Perceptron network. Rings correspond to neurons, squares correspond to variables and arrows correspond to parameters.*

incapable de généraliser à d'autres ensembles. Le dilemme biais-variance, présenté ci-après formalise ce phénomène.

B. Le piège du sur-apprentissage

1. Dilemme biais-variance

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

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

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

Même si le dilemme biais-variance ne s'applique en toute rigueur que dans

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

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

(20 % ou 30 % sont souvent cités pour les grands débits).

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

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

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

On pourra trouver en figure 4 les évolutions du biais et de la variance en fonction du nombre de paramètres libres du modèle. Ce dernier indicateur a été choisi pour mesurer la complexité du modèle car même s'il est généralement admis qu'il n'est pas le plus représentatif pour les modèles non linéaires, il est cependant souvent utilisé, ne serait-ce que du fait de sa simplicité.

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




Figure 4: Evolution du biais (trait pointillé) et de la variance (trait continu) en fonction du nombre de paramètres libres du modèle. Evolution of bias (dotted line) and variance (dashed line) as a function of the number of free parameters of the model.

On peut noter de plus sur cette illustration que le biais décroît bien au début tandis que la variance augmente globalement régulièrement en fonction de la complexité. Si la diminution du biais est rapide au début, en revanche ce dernier oscille pour les valeurs moyennes de complexité puis se met à augmenter pour les complexités élevées. Nous pensons que ce comportement du biais est dû aux incertitudes et au bruit de mesure qui l'entachent vraisemblablement d'une erreur liée à la variance (figure 5).

2. Mise en évidence du sur-apprentissage sur le bassin karstique du Lez

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

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

Dans l'exemple suivant, représenté en figure 5, nous reportons le score de qualité du modèle (basé sur le critère de Nash), ou score de validation croisée [Kong-A-Siou et al., 2012], en fonction du nombre de neurones cachés utilisés. Le critère de Nash, ou R^2 [Nash et Sutcliffe, 1970] permet d'évaluer la qualité des modélisations, il est calculé selon l'équation suivante :

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

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

La courbe illustre le phénomène de sur-apprentissage que nous avons évoqué au paragraphe précédent. Le modèle optimal est obtenu lorsque le score est maximal, c'est-à-dire pour 4 neurones cachés. Si le nombre de neurones cachés est supérieur, le modèle a une grande souplesse ce qui lui permet de très bien s'adapter aux données d'apprentissage mais aussi au bruit qu'elles contiennent. Son erreur en généralisation à un ensemble de validation inconnu devient alors grande ce qui fait chuter le score de validation croisée. L'hydrogramme obtenu pour un nombre trop grand de neurones cachés (figure 6-a) illustre bien le dilemme biais variance : la variance est importante et nuit à la qualité du modèle.

L'hydrogramme de simulation du débit du Lez obtenu pour le nombre optimal de neurones cachés est présenté en figure 6-b. Cette simulation est très satisfaisante (le coefficient de Nash est

de 0,95) et nous a encouragés à concevoir d'autres modèles, avec cette fois un horizon de prévision pouvant aller jusqu'à trois jours. Ces résultats sont présentés dans Kong A Siou et al. [2011] et montrent qu'une prévision de bonne qualité a pu être proposée jusqu'à un horizon de prévision de deux jours.

3. Sélection de variables pour optimiser la complexité

Le nombre de paramètres d'un réseau de neurones est lié principalement au nombre de neurones cachés et au nombre de variables ; en effet chaque variable d'entrée étant liée à chaque neurone caché par un paramètre à calculer, le nombre de paramètres sur la première couche est égal à n_v (nombre de variables) multiplié par n_h (nombre de neurones cachés). La complexité du modèle dépend donc tout autant des deux grandeurs. Pour cette raison le domaine de recherches ayant trait à la sélection de variables est très actif en




Figure 5: Score de validation croisée en fonction du nombre de neurones cachés. Cross-validation score versus the number of hidden neurons.




Figure 6: Hydrogrammes obtenus pour 8 neurones cachés (a) et 4 hidden neurones (b). Hydrographs obtained with 8 hidden neurons (a) and 4 hidden neurons (b).




Figure 7 : Figuration des différents processus impliqués pour constituer la réponse impulsionnelle du système. La courbe noire continue représente la réponse impulsionnelle du système, les différentes courbes pointillées représentent les contributions supposées de processus internes à l'hydrosystème. Elles interviennent à des temps de retard différents (abscisse) et sont ainsi associées à des temps de réponse différents. *Representation of the different processes involved in the impulse response. The black line represents the system impulse response; dotted lines correspond to supposed contributions of internal processes. These processes take part according to different delays (abscissa) and are thus associated to different response times.*

apprentissage statistique. Dans ce contexte, une approche originale a été proposée par Virgile Taver dans le cadre de sa thèse en cours pour l'hydrosystème du Lez. Dans ses travaux, V. Taver cherche à mettre en évidence les processus sous-jacents dans le système hydrologique afin de mieux dimensionner le modèle neuronal, et en particulier pour pouvoir représenter les processus liés à des composantes à long terme, par exemple les processus contribuant particulièrement au débit de base. Lorsque l'on applique les méthodes classiques de sélection de variables [Kong-A-Siou, 2011], les fenêtres temporelles de dimensionnement de l'historique de pluies à appliquer au modèle sont assez réduites (environ 10 jours selon de système étudié). Théoriquement, ces fenêtres peuvent permettre de prendre en compte les composantes à long terme, mais en pratique, on observe que ces dernières sont mal appréhendées. Ainsi pour optimiser le nombre de paramètres sans enlever d'informations au modèle, l'idée est de regrouper les entrées de pluies selon plusieurs plages temporelles dont les valeurs sont déduites de la réponse impulsionnelle. Rappelons que la réponse impulsionnelle est la réponse du système à une impulsion, à la fois très intense et très courte. Cette impulsion peut représenter, par exemple, un

orage très intense et très bref. Il est montré de manière théorique que cette réponse impulsionnelle est unique pour un système linéaire, c'est-à-dire un système décrit par une équation différentielle linéaire à coefficients constants. En revanche la réponse impulsionnelle n'est pas unique pour un système non linéaire car elle dépend de l'état de ce dernier : schématiquement la réponse à un orage n'est pas la même en crue ou en étiage. La première étape de la démarche est donc d'identifier sur la réponse impulsionnelle (calculée à partir du corrélogramme croisé pluie-débit) quels sont les différents processus sous-jacents identifiables par des ruptures de pente. Ceci est illustré pour le Lez sur la figure 7. Quatre fenêtres temporelles sont identifiées. Et dans ce cas particulier, le réseau de neurones va recevoir en entrée 4 sommes, chacune correspondant à un des sous processus identifiés. La première somme couvre, dans ce cas, la période de j (jours actuel) à $j-5$; la seconde les pluies de $j-6$ à $j-8$; la troisième de $j-9$ à $j-14$; la quatrième de $j-15$ à $j-20$. On note que la réponse impulsionnelle descend en deçà de la valeur de 0,2 signifiant que les sorties ne sont plus statistiquement linéairement corrélées aux entrées [Mangin, 1975]. Cependant le réseau de neurone étant un modèle non-linéaire il est possible qu'il

puisse tirer profit des variables d'entrées (pluies) pour les retards situés au-delà de ce seuil de 0,2.

Pour prendre en compte et expliciter ces différents processus, le réseau de neurones proposé n'est plus exactement le perceptron multicouche (tel que représenté en figure 3), mais comporte une couche supplémentaire de 4 neurones linéaires, chacun calculant la somme des entrées correspondant au processus auquel il contribue. Ce modèle est représenté en figure 8; si l'on considère uniquement les paramètres directement connectés aux entrées de pluies, il comporte 32 paramètres contre 48 pour le réseau classique du perceptron multicouche. Le nombre de paramètres est donc inférieur et l'historique de pluies pris en compte permet de représenter des processus à plus long terme. Si l'on regarde ensuite les performances des deux modèles : le perceptron multicouche dimensionné classiquement pour minimiser le nombre de paramètres (noté PMC) et le réseau contraint par l'information issue de la réponse impulsionnelle (noté IANN, comme *Information constrained Artificial Neural Network*), on note sur le tableau 1 que le second modèle est meilleur : la prise en compte des composantes à long terme a pu être réalisée tout en optimisant le nombre de paramètres grâce à l'introduction de contraintes dans le modèle.

C. Méthodologie de conception d'un modèle neuronal

Compte tenu des éléments théoriques et illustrations présentés précédemment, la méthodologie de conception d'un modèle neuronal doit permettre de proposer un modèle de complexité suffisante pour que la

		Nash ensemble de Test
PMC	moyenne	0,67
	médiane	0,68
	max	0,72
IANN	moyenne	0,75
	médiane	0,76
	max	0,79

Tableau 1 : Critères de Nash calculé sur les ensembles de test (modèle récurrent). *Nash criteria calculated on all test groups (recurrent model).*

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

D. Le paradigme systémique

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

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

E. Modèles hydrologiques par réseaux de neurones

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




Figure 8 : Architecture du modèle AINN (Information constrained Artificial Neural Network). La variable d'entrée ETP sera explicitée par la suite (paragraphe IV.b). Architecture of the model AINN (Information-constrained Artificial Neural Network). The input variable ETP is explained in the following (IV.b)

que l'équation différentielle liant les deux variables s'écrit :

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

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

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

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

où Δt est l'intervalle de temps séparant deux échantillons.

Ce qu'il est intéressant de noter est que le modèle de type réservoir est le modèle postulé du modèle physique de vidange d'un réservoir. Ce modèle postulé est récurrent, c'est un *filtre récursif non linéaire* : l'estimation de la sortie future $y(k+1)$ dépend au moins d'une sortie précédente $y(k)$. On pourra remarquer que l'équation aux différences

précédente peut être implémentée par un neurone unique ayant comme variable exogène (ou extérieure) $x(k)$ et comme variable de bouclage $y(k-1)$.

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

F. Modèles de prédicteur optimal

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

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

Où φ est une fonction qui représente le fonctionnement du système




Figure 9: Modèle postulé récurrent.
Postulated recurrent model.

physique étudié. Le modèle postulé reçoit en entrée les variables exogènes à l'instant k (vecteur $u(k)$) et la sortie $y(k)$; sa sortie est $y(k+1)$. q^{-1} est l'opérateur retard. r et w sont des entiers positifs qui correspondent à un historique sur les données présentées au modèle.

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

1. Hypothèse bruit de sortie

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

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

$$u(k), \dots, u(k-w+1), \theta)$$

où g_m est la fonction réalisée par le réseau de neurones, $y(k)$ la sortie du réseau, $u(k)$ le vecteur des variables exogènes, r et w sont des entiers positifs, θ est le vecteur des paramètres (figure 10).





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



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

2. Hypothèse bruit d'état

Dans l'hypothèse *bruit d'état* (figure 11), le modèle postulé est soumis à des perturbations additives sur son état ($b(k+1)$), par exemple le modèle a été mal calibré ou le bassin versant a subi des modifications qui ont fait évoluer son comportement (pressions anthropiques, changement climatique, déforestation, etc.).

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

$$y^s(k+1) = g_m(y^p(k), \dots, y^p$$

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




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

Où g_m est la fonction réalisée par le réseau de neurones, $y(k+1)$ la sortie du réseau, $u(k)$ le vecteur des variables exogènes, r et w sont des entiers positifs, θ est le vecteur des paramètres (figure 11).

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

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

III. Modélisation pluie-débits

A. Comparaison des modèles récurrent et non-récurrent

La méthodologie esquissée au paragraphe II.c. a été appliquée à la modélisation de la relation pluie-débit du bassin du Baget [Johannet et al., 2008b]. Les entrées de pluies sont les précipitations journalières à la station de Balagué et les débits sont ceux mesurés à l'aval du bassin. Sont représentées en figure 12 les évolutions des pluies et du débit durant l'année 1999 qui est l'année de test de notre étude ; on y note un étiage prononcé durant l'été et le début de l'automne et une période de hautes eaux durant l'hiver et le

printemps. De manière contrastée avec le bassin karstique du Lez, on peut noter que la pluie est persistante durant toute l'année ce qui n'empêche pas, du fait de l'évapotranspiration, que le débit marque un étiage très net.

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

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

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

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

Il apparaît donc que la modélisation par réseaux de neurones est fiable pour effectuer la prévision à « un coup » (modèle non-récurrent), est qu'elle est moins satisfaisante pour la prévision à plus longue échéance (modèle récurrent). Néanmoins l'on peut comprendre

que le modèle récurrent qui calcule le débit à partir des seules informations de pluie et de débit ne peut anticiper sur les différences de comportement de l'aquifère en l'absence d'information sur l'évapotranspiration potentielle, ou en l'absence d'information comme la température. En revanche, le modèle non-récurrent ne souffre pas de la même limitation car les mesures du débit observé qu'il reçoit en entrée peuvent le renseigner

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

En conséquence, si l'on veut utiliser le modèle récurrent à des fins de prévision à moyen ou long terme en

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

Tableau 2 : Présentation synthétique des meilleures architectures définies. *Synthetic presentation of the best defined architectures.*




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




Figure 13: Évapotranspiration potentielle a priori. *A priori potential evapotranspiration*




Figure 14: Estimation de débit réalisée par un filtre linéaire. En noir la sortie mesurée, en vert la sortie du modèle linéaire, en bleu la sortie du modèle neuronal. *Estimated discharge by linear filtering. In black, the measured discharge, green the linear filter, blue the output of the neural model.*

disposant de prévision des précipitations, il convient d'appliquer une autre entrée qui puisse alimenter le modèle avec une information relative à l'évapotranspiration.

B. Prise en compte de l'évapotranspiration

Afin de prendre en compte l'évapotranspiration, l'approche classique consisterait à utiliser une formule d'estimation de l'évapotranspiration (la formule de Turc par exemple) et à laisser le réseau apprendre. En l'absence de mesures de températures, il est néanmoins possible de présenter au réseau un signal d'entrée qui n'est pas construit en fonction de la température mesurée, mais d'une variation a priori de l'évapotranspiration potentielle [Johannet 2010]. Ainsi, nous pouvons construire une fonction en cloche qui possède sa valeur maximale en été et minimale en hiver : à charge au réseau de neurones de la transformer pour intégrer l'évapotranspiration à son estimation (figure 13).

De nouvelles simulations sont alors réalisées en intégrant cette évapotranspiration a priori comme entrée au modèle sur une fenêtre temporelle de même largeur que celle des précipitations. L'estimation du modèle récurrent

comportant en entrées les précipitations, l'évapotranspiration a priori et les débits estimés précédents, donne un hydrogramme simulé dont le critère de Nash vaut maintenant 0,72 par rapport au débit observé. La simulation a donc bien été améliorée.

En l'absence de données climatiques complémentaires il est difficile d'aller au-delà de ces résultats mais il est intéressant de les comparer à ce qu'aurait obtenu un système purement linéaire. Nous avons pour cela réalisé le calcul d'un filtre linéaire identifiant la relation pluie-débit, comportant l'entrée

évapotranspiration a priori. Comme attendu, les résultats sont moins bons qu'avec le réseau de neurones, et le critère de Nash obtenu vaut 0,64. L'hydrogramme obtenu est le suivant (figure 14), il est visiblement moins bon que celui relatif à l'estimation réalisée par le réseau récurrent, en particulier pour les pics de l'automne et pour la période d'étiage où le filtre linéaire « invente » des crues lors des épisodes pluvieux : il n'arrive pas à traiter correctement le signal fictif d'évapotranspiration a priori.

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

Il apparaît donc que la modélisation effectuée par le réseau de neurones met bien à profit ses capacités de modélisation de phénomènes non linéaire. On trouvera dans [Johannet 2010] une autre illustration de ces capacités de modélisation non-linéaires qui laisse à penser que le karst du Baget a un rôle atténuateur vis-à-vis des crues les plus intenses. Ce comportement observé sur le modèle paraît tout à fait cohérent avec ce que l'on peut connaître du comportement des karsts en état de crue.




Figure 15: Estimation des débits en étiage. Trait noir : débit observé, trait pointillé bleu débit estimé par le modèle non-récurrent ; trait tireté vert : débit simulé par le modèle récurrent ; tireté rouge : débit estimé par le filtre linéaire. *Estimation of discharge in low flow period. Black line : observed discharge, blue dashed line : discharge estimated by the non-recurrent model ; green dashed line : by the recurrent model ; red dashed line : by linear filtering.*

IV. Vers une meilleure connaissance des systèmes étudiés

Dans les paragraphes précédents, nous avons pu présenter comment un modèle à réseaux de neurones pouvait réaliser une fonction a priori inconnue et complexe, comme celle de la relation pluie-débit d'un aquifère karstique, pourvu que des bases de données soient disponibles et que l'écueil du sur-apprentissage soit bien appréhendé. Les applications en prévision ou simulation peuvent alors apporter des bénéfices aux enjeux sociétaux tels que la prévision des crues ou des étiages. Néanmoins, compte tenu des bons résultats obtenus, nous avons émis l'hypothèse que le modèle neuronal réalisait une fonction proche de celle effectuée par le modèle physique, tout au moins sur un certain domaine de validité. Ainsi, autant pour valider cette hypothèse que pour mieux connaître le comportement des aquifères karstiques, nous avons cherché à extraire des informations du modèle neuronal réalisé. Deux méthodes ont été proposées qui sont présentées ci-dessous : la méthode KnoX et les boîtes transparentes.

A. Boîtes transparentes

L'approche des boîtes transparentes a été utilisée dans l'exemple suivant pour estimer le signal d'évapotranspiration. Cette information est en effet cruciale pour les modèles hydrologiques qui opèrent souvent sur les pluies efficaces². Si plusieurs modèles d'évapotranspiration existent, il a également été montré par L. Oudin que la précision du modèle d'évapotranspiration n'a que peu d'importance et qu'un modèle assez rustique ne prenant en compte que

l'évolution de la température pour estimer l'évapotranspiration potentielle peut suffire [Oudin, 2004].

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

Appliquées aux données du karst du Baget, présenté en section I.a, et après plusieurs raffinements successifs, nous avons obtenu pour l'évapotranspiration observée dans le réseau de neurones (figure 16) une courbe différente de la gaussienne appliquée en variable d'entrée. On peut y noter en particulier une translation systématique du maximum au mois de septembre [Johannet et al., 2008a]. L'interprétation de ce maximum n'est pas très aisée à faire. En effet, la sortie du neurone « évapotranspiration » est le résultat d'un calcul effectué sur des variables d'entrée qui ne dépendent pas de la pluie, on penserait donc observer l'évapotranspiration potentielle. Or, il faut se souvenir que le calcul des paramètres a été effectué à partir d'une erreur calculée en sortie, qui dépend donc des précipitations observées, et ferait alors intervenir l'évapotranspira-

tion réelle. Ce que l'on obtient à la sortie du neurone « évapotranspiration » est donc une grandeur différente des deux précédentes, qui transcrit l'eau que la végétation consomme, que cette eau vienne d'être précipitée, ou qu'elle se situe dans des réserves plus profondes. Il s'agirait d'un *déficit en écoulement* moyen causé par la végétation et l'évaporation. Cette notion serait intéressante à discuter car elle a plus de sens, hydrologiquement parlant, que celle d'évapotranspiration, qui est avant tout une notion introduite en agronomie.

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

B. Méthodologie KnoX

La méthodologie KnoX, comme Knowledge eXtraction a été appliquée à l'hydrosystème du Lez. Afin de mieux connaître les écoulements souterrains de cet hydrosystème, un découpage du bassin d'alimentation supposé en quatre zones géologiques estimées homogènes a été proposé par Line Kong A Siou lors de son travail de thèse [Kong-A-Siou, 2011], ce découpage est présenté au paragraphe II-b. Relativement à chacune des zones baptisées nord-est, nord-ouest, sud-est et sud-ouest, nous avons défini autant de chroniques pour des pluviomètres dits « virtuels » qui enregistraient les précipitations tombant sur ces zones (figure 2). Ces chroniques ont été définies à partir de six pluviomètres présents dans le bassin ou à proximité de celui-ci en utilisant une méthode géométrique de pavage du plan (polygones de Thiessen) afin de définir la « contribution » de chacun de ces pluviomètres à chaque zone.

Nous avons émis l'hypothèse selon laquelle l'eau tombant sur chacune de ces zones : i) alimente l'aquifère profond, ii) ressort à la source du Lez, iii) sort à un autre exutoire. En contraignant l'architecture du réseau de neurones par ces hypothèses, un modèle hypothèse a été proposé tel que représenté sur la figure 17. Sa mise en œuvre a été simplifiée par souci de parcimonie et les réseaux de type identificateur universel


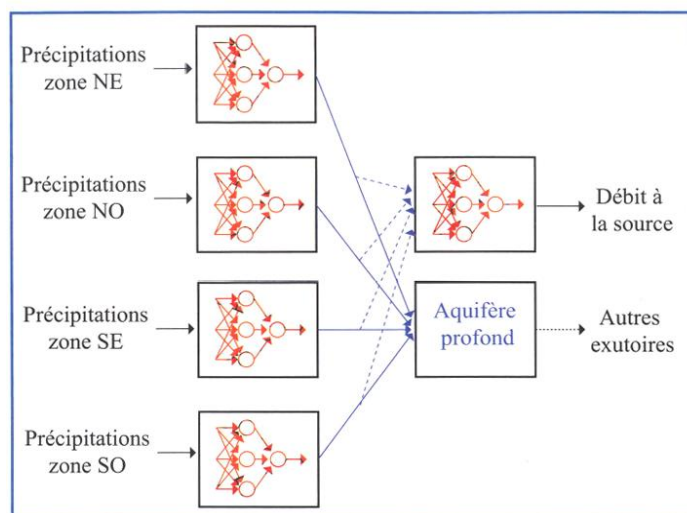


Figure 16 : Boîte transparente pour mettre en évidence le déficit d'écoulement. 16a. Modèle postulé (hypothèse physique). 16b. Déclinaison de l'hypothèse physique en utilisant un réseau de type perceptron multicouche pour identifier chacune des fonctions physiques inconnues. *Transparent box to visualize water losses. a) postulated model (physical hypothesis). b) Deflection of the physical hypothesis, using a multilayer perceptron network to identify every unknown physical function.*

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

Figure 17 : Modèle postulé pour la simulation hydrodynamique de l'aquifère du Lez. *Postulated model for the hydrodynamic modelling of the Lez hydrosystem.*



correspondant à l'infiltration de chacune des zones ont été remplacés par un seul neurone linéaire. De l'information a été extraite de chacun de ces sous-réseaux en utilisant la méthode de sélection de variables proposée par [Yacoub et Bennani, 2001] qui permet de quantifier l'importance de chacune des variables. Ainsi, nous avons pu extraire, pour chacune des zones, d'une part le volume relatif de l'eau sortant à la source provenant de cette zone et d'autre part le temps de transfert de l'énergie³ issue des précipitations tombant sur la zone [Kong-A-Siou et al., 2013].

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

Appliquée dans un second temps au bassin d'alimentation du Lez, la méthode fournit les pourcentages de contribution de chaque zone au débit observé à la source (tableau 4). Les

contributions sont estimées à partir des paramètres médians correspondant à 50 réseaux obtenus à partir d'initialisations différentes des paramètres du réseau de neurones afin de s'affranchir d'un cas particulier.

Les contributions des zones au débit de la source appellent plusieurs commentaires. A la première lecture, on est surpris de la faible importance de la zone sud-ouest qui est pourtant une zone de recharge importante de l'aquifère ; cependant cette faible contribution est explicable car la source du Lirou draine cette zone en hautes eaux (on ne peut actuellement calculer cette contribution car la source du Lirou n'est jaugée que depuis peu de temps). Les contributions des zones nord-ouest et nord-est correspondent à ce que l'on peut attendre : on sait que la zone nord-est contribue directement à l'alimentation de la source puisque des mesures de hauteur d'eau dans la nappe montrent qu'elle est directement influencée par les pompages effectués dans le drain du Lez. En effet,

des piézomètres implantés sur le site du Terrieu situé à quelques kilomètres de la source voient le niveau de la nappe baisser très rapidement lorsque le pompage dans le Lez est effectif [Jazayeri Noushabadi, 2009]. Par ailleurs la contribution de la zone nord-ouest doit arriver à la source à la faveur de la faille de Corconne, accident tectonique majeur qui sépare le bassin d'alimentation en deux et draine l'eau vers le sud. Enfin, la très faible importance de la contribution de la zone sud-est paraît indiquer que cette zone est peu ou pas comprise dans le bassin d'alimentation de la source. Ceci étant d'autant plus justifié que la zone sud-est est constituée de terrains imperméables (avec quelques aquifères perchés) sur lesquels l'eau ruisselle pour atteindre le fleuve du Lez à l'aval de la source. Quelques apports marginaux à l'aquifère pourraient cependant se produire à la faveur de failles.

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

Contribution au débit	Z ₁	Z ₂	Z ₃	Z ₄
Imposée dans le bassin-versant virtuel	33,9 %	37 %	8,4 %	19,2 %
Extrait du modèle neuronal (moyenne sur quatre bassins virtuels différents)	35,3 %	37,3 %	8,8 %	18,5 %
Ecart type	2,86 %	3,49 %	3,49 %	1,66 %

Tableau 3 : Validation de la méthode KnoX à partir d'un aquifère virtuel. *Validation of the KnoX method starting from a virtual aquifer.*

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

Tableau 4 : Contribution des zones estimée par la boîte transparente. *Contribution of the zones, estimated by the transparent box.*

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

Conclusion

Cet article a présenté comment les réseaux de neurones, méthode de modélisation issue de l'intelligence artificielle, pouvaient aider à mieux appréhender le fonctionnement hydrodynamique des aquifères karstiques grâce à leur capacité à représenter de manière empirique des fonctions a priori inconnues. Grâce à cette propriété les réseaux de neurones sont donc tout particulièrement adaptés à représenter les fonctions réalisées par les hydrosystèmes complexes ou hétérogènes pour lesquels il n'existe pas de modèle physique, par manque de connaissance. Après une présentation simplifiée du fonctionnement de ces systèmes appartenant à l'apprentissage statistique, leur limite – le dilemme biais-variance – a été présentée et illustrée. Partant d'un modèle de type boîte noire dans lequel aucune information sur les processus n'était apportée au modèle, il a été

montré qu'il était possible de réaliser efficacement des fonctions telles que la simulation des débits d'une source karstique. Autant par souci de validation des modèles ainsi obtenus que pour améliorer leurs performances, il a ensuite été proposé de contraindre l'architecture du modèle sous la forme de schéma-bloc afin de pouvoir calculer, par le réseau de neurones, chacun des blocs de ce modèle hypothèse. Inspirés de ce principe, deux types d'approches ont été présentés: l'une appelée « boîte transparente » a permis d'extraire du modèle une information sur le « déficit d'écoulement hydraulique » ; l'autre baptisée KnoX a permis de mieux déterminer l'origine des eaux souterraines et de mieux quantifier les temps de transferts au sein de l'aquifère. Ainsi, les réseaux de neurones, grâce à une méthodologie de conception rigoureuse, loin de leur réputation d'objets mathématiques invérifiables, ont pu permettre d'amé-

liorer la connaissance que nous avons de deux hydrosystèmes karstiques: le Lez (Hérault) et le Baget (Ariège). Ces méthodes étant génériques et transposables à d'autres aquifères dès que l'on dispose d'une base de données suffisante, nous pensons qu'un vaste champ d'applications et d'échanges fructueux entre les communautés des modélisateurs et des karstologues de terrain peut être exploré par de telles approches.

Remerciements

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

ALT F.L., 1972 - Archaeology of computers: Reminiscences, 1945-1947. In Communications of the ACM, special issue: Twenty-fifth anniversary of the Association for Computing Machinery, vol. 15 7, pp. 693-694.
BENDER E., 1996 - *Mathematical Methods in Artificial Intelligence*. IEEE Computer Society Press, 636 p.
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.
BORRELL-ESTUPINA V., LADOUCHE B., MALATERRE P.-O., RICCI S., CABALLERO Y., COUSTAU M., DÖRFLIGER N., FLEURY P., JAY-ALLEMAND M., MARÉCHAL J.-C. and THUAL O., 2014 - *Forecasting and mitigation of flooding in a Mediterranean karstic watershed*. Hydrology in a Changing World: Environmental and Human Dimensions Proceedings of FRIEND-Water 2014, Hanoi, Vietnam, February 2014 (IAHS Publ. 36x).
BOX G.E.P., 1979 - *Robustness in the strategy of scientific model building*. In Robustness in Statistics, R.L. Launer, G.N. Wilkinson, ed.
DREYFUS G., SAMUELIDES M., MARTINEZ J.-M., GORDON M.-B., BADRAN F., THIRIA S. et HÉRAULT L., 2008 - *Apprentissage statistique*. Eyrolles, 450 p.
FLEURY P., LADOUCHE B., CONROUX Y., JOURDE H. and DÖRFLIGER N., 2008 - Modelling the hydrologic functions of a karst aquifer under active water management - The Lez spring, *Journal of Hydrology*, 365 (3-4), 235-243.
FLEURY P., CHARLIER J.-B., BORRELL V. et COUSTAU M., 2011 - Appui au SCHAPI 2011 - Module 1 - Mise en place d'un indicateur d'aide à la décision pour la prévision de crue en milieu karstique: les bassins versants du Lez et de la Tardoire. Rapport BRGM RP-60380-FR.
GALLINARI P. and CIBAS T., 1999 - Practical complexity control in multilayer perceptrons. In *Signal Processing* 74: 29-46
GEMAN S., BIENENSTOCK E. and DOURSAT R., 1992 - Neural networks and the bias/variance dilemma. *Neural Computation* 4(1): 1-58.

HORNIK K., STINCHCOMBE P. and WHITE H., 1989 - Multilayer feed-forward neural networks are universal approximators. *Neural Networks* 2: 359-366
JAZAYERI NOUSHABADI M. R., 2009 - Characterisation of relationships between fracture network and flow-path Network in fractured and karstic reservoirs. Numerical modeling and field investigation (Lez aquifer, Southern France). Thèse Université Montpellier II.
JOHANNET A., VAYSSADE B. and BERTIN D., 2008a - Neural Networks: From Black Box Towards Transparent Box. Application to Evapotranspiration Modeling. In *International Journal of Computational Intelligence* 4 (3): 163-170
JOHANNET A., MANGIN A. et VAYSSADE B., 2008b - Modélisation d'un système karstique par réseaux de neurones. Simulation des débits du karst du Baget-France. In *Karsts de montagne, Cahiers de Géographie, Collection EDYTEM n° 7*: 51-62
JOHANNET A., 2010 - *Artificial Neural Networks*. In *Environmental hydraulics 2: Mathematical Models*, J.M.Tanguy, ed.
KARAM Y., 1989 - *Essai de modélisation des écoulements dans un aquifère karstique. Exemple de la source du Lez (Hérault, France)*. Thèse Université Montpellier II Sciences et Techniques du Languedoc.
KONG-A-SIOU L., 2011 - *Modélisation des crues de bassins karstiques par réseaux de neurones. Cas du bassin du Lez (France)*. Thèse université Montpellier II.
KONG-A-SIOU L., JOHANNET A., BORRELL V. and PISTRE S., 2011 - Complexity selection of a neural network model for karst flood forecasting: The case of the Lez Basin (southern France). *Journal of Hydrology* 403 (367-380)
KONG-A-SIOU L., JOHANNET A., BORRELL ESTUPINA V. and PISTRE S., 2012 - Optimization of the generalization capability for rainfall-runoff modeling by neural networks: The case of the Lez aquifer (southern France). *Environmental Earth Sciences* 65 (8): 2365-2375
KONG-A-SIOU L., CROS K., JOHANNET A., BORRELL-ESTUPINA V. and PISTRE S., 2013 - KnoX method, or KnowledgeXtraction from neural network

model. Case study on the Lez aquifer (southern France). *Journal of Hydrology* 507 (19-32)
MARJOLET G. et SALADO J., 1976 - Contribution à l'étude de l'aquifère karstique de la source du Lez (Hérault). Thèse Université des Sciences et Techniques du Languedoc (Montpellier).
MANGIN A., 1970 - Le système karstique du Baget (Ariège). *Annales de Spéléologie*, 25, 3.
MANGIN A., 1975 - Contribution à l'étude hydrodynamique des aquifères karstiques. Thèse Université de Dijon. Laboratoire souterrain du Centre national de la recherche scientifique.
NASH J.E. and SUTCLIFFE J.V., 1970 - River flow forecasting through conceptual models part I - A discussion of principles, *Journal of hydrology* 10(3), 282-290.
NERRAND O., ROUSSEL-RAGOT P., PERSONNAZ L., DREYFUS G. and MARCOS S., 1993 - Neural networks and nonlinear adaptive filtering: Unifying concepts and new algorithms. *Neural Computation*, 5(2) : 165-199.
L. OUDIN., 2004 - *Recherche d'un modèle d'évaporation potentielle pertinente comme entrée d'un modèle pluie-débit global*. Thèse de doctorat, ENGREF, Paris, 290 p.
PALOC H., 1979 - *Alimentation en eau de la ville de Montpellier. Localisation d'un emplacement de captage dans le réseau souterrain de la source du Lez. Détermination de ses principales caractéristiques en préalable à l'exécution des travaux*, BRGM/79-SGN-654-LRO, BRGM, Montpellier.
PRESS W.H., TEUKOLSKY S.A., VETTERLING W. T. and FLANNERY B.P., 1992 - *Numerical Recipes in C*, Cambridge University Press
ROUCH R., 1982 - Le système karstique du Baget. La communauté des Harpacticides. Comparaison de la dérive des Harpacticides à l'entrée et à la sortie de l'aquifère. *Ann. Limnol.*, 18, 2, p. 133-150.
YACOUB M. et BENNANI Y., 2001 - Une mesure de pertinence pour la sélection de variables dans les perceptrons multicouches, In *Revue d'Intelligence Artificielle*, 15 : 393-410.