



Modélisation par apprentissage statistique des systèmes naturels, ou en interaction avec un environnement naturel. Applications aux karsts, crues éclair et en robotique

Anne Johannet

► To cite this version:

Anne Johannet. Modélisation par apprentissage statistique des systèmes naturels, ou en interaction avec un environnement naturel. Applications aux karsts, crues éclair et en robotique. Réseau de neurones [cs.NE]. Université Pierre et Marie Curie - Paris VI, 2011. tel-00745131

HAL Id: tel-00745131

<https://theses.hal.science/tel-00745131v1>

Submitted on 24 Oct 2012

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.



Modélisation par apprentissage statistique des systèmes naturels, ou en interaction avec un environnement naturel.

Applications aux karsts, crues éclair et en robotique

Mémoire d'Habilitation à Diriger les Recherches

présenté et soutenu publiquement par :

Anne Johannet

le 22 juin 2011 devant le jury composé de :

Rapporteurs :

Professeur Cesare Alippi, Politecnico di Milano

Professeur Denis Dartus, Institut de Mécanique des Fluides de Toulouse

Professeur Moumtaz Razack, Université de Poitiers

Examinateurs :

Professeur Gérard Dreyfus, ESPCI-ParisTech

Professeur Patrick Gallinari, Université Pierre et Marie Curie

Monsieur Alain Mangin, Chargé de Mission CNRS

Professeur Séverin Pistre, HydroSciences Montpellier

Professeur Manuel Samuelides, Institut Supérieur de l'Aéronautique et de l'Espace

A Dominique, compagnon de mes espoirs et de mon travail, patient conseiller et correcteur sans faille de mes essais, père de la plateforme de développement ANNE¹ et papa de mes quatre fils...

A Pierre, Bruno, Roland et Louis, mes supporters inconditionnels...

¹ Artificial Neural Networks Environment

Remerciements

J'ai un grand plaisir à remercier Monsieur Gérard Dreyfus qui m'a tout d'abord proposé un stage de DEA dans son Laboratoire de l'ESPCI pour contribuer à la réalisation d'un émulateur de microprocesseur 68000. Il m'a ensuite fait confiance en me proposant de rejoindre son équipe de recherche pour effectuer ma thèse sur l'implémentation électronique du réseau de Hopfield, puis comme Maître de Conférences. Sa grande rigueur et sa disponibilité m'ont beaucoup appris. Nos chemins se sont croisés à nouveau lorsque j'ai renoué avec la recherche en 2006 et qu'il a accepté de diriger les thèses que je souhaitais mener sur la prévision des crues des bassins rapides. Il a toute ma gratitude pour avoir accepté de consacrer son temps, son expérience et son expertise aux activités de recherches que je développais. Je le remercie également de m'avoir accompagnée au début de ce projet de HDR et d'avoir accepté d'examiner mon travail.

Egalement, ma gratitude va à Monsieur Séverin Pistre qui m'a fait confiance en dirigeant les thèses que je souhaitais mener sur la modélisation des karsts ; sa grande connaissance du bassin du Lez et ses qualités humaines m'ont beaucoup enrichie. Je le remercie vivement d'avoir accepté d'examiner ce travail.

Monsieur Alain Mangin m'a ouvert la porte de son Laboratoire et ses bases de données lorsque je suis allée le rencontrer. Son soutien scientifique, à chaque fois que je l'ai sollicité, a permis à mon projet de modélisation hydrodynamique des karsts d'aboutir. Je suis à la fois flattée et ravie qu'il ait accepté d'examiner mon travail, je l'en remercie sincèrement.

Je suis très honorée que Messieurs Cesare Alippi, Denis Dartus et Moumtaz Rasak aient accepté d'être les rapporteurs de ce travail, qu'ils soient ici remerciés de leur contribution décisive.

Pour l'honneur qu'ils m'ont fait d'examiner ce travail, je remercie Messieurs Patrick Gallinari et Manuel Samuelides. J'espère que le volet hydrologique de ce mémoire leur permettra d'appréhender avec intérêt les difficultés de l'étude de ces systèmes.

Pour m'avoir acceptée au Centre des Matériaux de Grande Diffusion de l'Ecole des Mines d'Alès en 2006, je remercie Madame Mireille Fouletier ; de la même façon, Messieurs Yannick Vimont, José-Marie Lopez-Cuesta et Eric Garcia-Diaz m'ont permis de poursuivre mes recherches dans des conditions favorables et agréables, je les en remercie.

Je voudrais aussi remercier chaleureusement les collègues avec qui j'ai pu travailler et qui m'ont accueillie avec amitié : Michel Artigue, Pierre-Alain Ayral, Nathalie Azéma, Roland Bataille, Pierre Couturier, Sylvie Cruvellier, Daniel Diep, Pierre Gaudon, Danièle Larroze, Isabelle Marc, Alexandre Meimouni, Hugues Silvain, Bernard Vayssade, Jean-Paul Veuillez. Je n'oublie pas la force de frappe de la recherche bibliographique qui, à l'Ecole des Mines d'Alès prend la forme d'une équipe sympathique, serviable et compétente. Que Hélène Alegre de la Sougeole, Françoise Armand, Cécile Chabanne, Ghislaine Tournier et Jean Claude Vézilier maintenant à la retraite, soient ici remerciés pour leur grande culture, et la gentillesse avec laquelle ils effectuent les recherches que nous leur demandons.

Parmi tous mes collègues et maintenant amis, je tiens à remercier plus particulièrement Messieurs Pierre Roussel-Ragot et Marc Vinches qui ont cru en moi et m'ont soutenue à chaque fois que cela était nécessaire, je les remercie également vivement, ainsi que Monsieur Pierre Couturier, pour la relecture de ce mémoire.

Je n'oublie pas non plus les étudiants de doctorat qui m'ont fait confiance en s'inscrivant sous mon encadrement ; que Guillaume Artigue, Julien Bongono, Audrey Bornancin Plantier, Line Kong-A-Siou reçoivent ici également mes remerciements ; leur participation aux travaux de recherche est des plus importantes.

Parmi tous les étudiants de Master 2 ou de DEA que j'ai eu le plaisir d'encadrer, je me souviens tout particulièrement de Sarah Eurisouké, de Jean Philippe Amouroux et de Kévin Cros, je les remercie ici pour leur enthousiasme, leur sérieux et la bonne volonté avec laquelle ils ont mis leur talent à la disposition de nos activités de recherche.

On ne peut remercier tous ceux qui ont contribué à l'évolution de la pensée, mais je souhaiterais cependant remercier ici pour leurs discussions intéressantes, leurs conseils, et la gentillesse avec laquelle ils ont partagé leurs connaissances ou ressources bibliographiques : Mesdames Valérie Borrel, Nathalie Dorfliger et Caroline Wittwer, Messieurs Michel Bakalowicz, Marcel Meyssonnier, Henri Paloc et Georges-Marie Saulnier.

Enfin, je tiens aussi à remercier tous les collègues de l'Ecole des Mines d'Alès qui contribuent également à nos recherches, non seulement l'ensemble des membres du CMGD pour leur gentillesse et la bonne ambiance de travail, mais également les services techniques, le restaurant et le garage, sans oublier le service reprographie pour les duplications de mes polycopiés de cours, des mémoires des doctorants et de ce mémoire ci.

Avertissement

J'ai voulu que ce mémoire, qui traite principalement des disciplines de l'hydrologie et de l'apprentissage statistique, ainsi que de l'identification des systèmes puisse être compris et apprécié intégralement par les spécialistes de chacune de ces disciplines. A cette fin j'ai redéfini certains concepts sur lesquels se fondait mon raisonnement dans ces disciplines ; ces définitions n'auraient sûrement pas eu leur place dans un mémoire proposé à un public monospécialisé. En supplément à ces définitions fondamentales, le lecteur trouvera des renvois à de nombreuses notes de bas de page, dont l'objet est de conserver une lecture fluide du texte principal, tout en apportant les compléments d'informations pour les non spécialistes du terme expliqué dans la note.

J'espère que ces choix, pédagogiques, permettront à chacun d'apprécier ce travail ainsi que son exposé qui s'est attaché à satisfaire les contraintes de l'exercice, précisées par l'Université Pierre et Marie Curie (synthèse d'une quarantaine de pages maximum).

SOMMAIRE

I. Introduction : pourquoi l'apprentissage ?	13
II. L'apprentissage statistique	17
a. Maximum de vraisemblance et moindres carrés, autres fonctions de coût	17
b. Critères de performance	18
i. Des critères adaptés à l'objectif	18
ii. Vers l'ajustement de la fonction de coût à l'objectif.....	19
II.2. DILEMME BIAIS-VARIANCE	20
a. Présentation.....	20
b. Illustrations pour un système dynamique.....	21
III. Les réseaux de neurones.....	23
III.1. MODÈLES DE NEURONES ET D'ARCHITECTURES.....	23
III.2. IDENTIFICATION UNIVERSELLE ET PARCIMONIE	24
III.3. RÉSEAUX DYNAMIQUES	25
a. Modèles de prédicteur optimal	25
i. Hypothèse bruit de sortie	26
ii. Hypothèse bruit d'état	27
III.4. APPRENTISSAGE	29
a. Apprentissage des systèmes dynamiques	29
b. Illustration : synthèse de l'asservissement d'une pince électropneumatique	30
i. Identification du processus.....	32
ii. Contrôle de la pince électropneumatique	33
III.5. SÉLECTION DE VARIABLES.....	34
III.6. MÉTHODES DE RÉGULARISATION.....	35
a. Régularisation par sélection de modèle.....	35
b. Régularisation par diminution de la valeur des paramètres.....	36
c. Avantages du couplage de plusieurs méthodes.....	37
d. Vers un outil de compréhension du modèle.....	37
III.7. APPRENTISSAGE PAR RENFORCEMENT	38
a. Fonction objectif	38
b. Adaptativité en milieu non stationnaire.....	39
i. Apprentissage de comportements d'un robot hexapode	39
ii. Vers l'assimilation de données en hydrologie	41
III.8. APPLICATION AUX HYDROSYSTÈMES.....	42
a. Projets BVNE et ANR FLASH	42
b. Systèmes karstiques	45
IV. Au delà de la boîte noire.....	49
IV.1. BOÎTE GRISE ET BOÎTE TRANSPARENTE	49
a. Modélisation semi-physique	49

b. Estimation empirique de grandeurs physiques	50
<i>i. Estimation de l'évapotranspiration</i>	<i>50</i>
<i>ii. Estimation de transferts d'eau souterrains</i>	<i>51</i>
<i>iii. Vers la connaissance des volumes d'eau stockés dans les karsts.....</i>	<i>55</i>
V. Conclusion.....	57
VI. Références bibliographiques	59
Annexes.....	65
RÉSUMÉ DES TRAVAUX DE RECHERCHE	65
LISTE DES PUBLICATIONS	67
PROJET DE RECHERCHES À 4 ANS	73
SYNTHÈSE DES ACTIVITÉS D'ENSEIGNEMENT	75
JURYS DE THÈSES ET ENCADREMENTS	79

Liste des Figures

Figure 1. Distribution statistique de variables journalières de 1987 à 2005.	18
Figure 2 : Evolution du biais (trait pointillé) et de la variance (trait continu) en fonction du nombre de paramètres libres du modèle.	22
Figure 3 : Réseau Perceptron Multicouche	24
Figure 4 : Modèle postulé récurrent.	26
Figure 5 : Modèle postulé (5.a) et prédicteur associé (5.b) à l'hypothèse bruit de sortie.....	26
Figure 6 : Modèle postulé (6.a) et prédicteur associé (6.b) à l'hypothèse bruit d'état.	28
Figure 7 : Représentation des erreurs de mesures des entrées exogènes, vues comme une perturbation additive sur l'état.	28
Figure 8 : Apprentissage d'un réseau dynamique avec la méthode des copies.	30
Figure 9 : Schéma de la pince électropneumatique	31
Figure 10 : Schéma élémentaire d'un asservissement.....	31
Figure 11 : Stratégie d'identification de la pince électropneumatique. (Couturier, 1998).....	33
Figure 12 : Validation croisée	36
Figure 13 : Illustration de l'évolution du score de validation croisée (ici fondé sur le R^2), en fonction du nombre de neurones cachés (Kong A Siou, 2011-a).	38
Figure 14 : Schéma de principe de l'apprentissage par renforcement	39
Figure 15 : Robot hexapode	40
Figure 16 : Les deux types de marche hexapode découverts.	41
Figure 17 : Bassin versant d'Anduze (Artigue, 2010).	44
Figure 18 : Réponse du modèle à des impulsions croissantes de précipitation simulée.	47
Figure 19 : Boîte transparente pour mettre en évidence l'évapotranspiration	51
Figure 20 : Bassin d'alimentation supposé du Lez	52
Figure 21 : Boîte transparente pour la simulation hydrodynamique de l'aquifère du Lez.	53
Figure 22 : Modèle systémique du karst et sa boîte transparente.....	56

Liste des Tables

Tableau 1 : Validation de la méthode à partir d'un aquifère virtuel.	54
Tableau 2 : Contribution des zones estimée par la boîte transparente	54

"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]

I. Introduction : pourquoi l'apprentissage ?

L'objet du premier exercice du cours d'automatique que je propose aux étudiants découvrant cette matière est de les sensibiliser à la complexité du monde et au fait que, par exemple, la simple action de marcher droit, les yeux fermés, le long d'un chemin nécessite une description parfaite de l'environnement, ainsi qu'une maîtrise parfaite de leurs propres actionneurs. A défaut de cette description, il est nécessaire d'ouvrir les yeux pour utiliser le retour d'information visuelle effectué par la contre réaction qui permet de calculer une erreur et ainsi de se repositionner par rapport à l'objectif. Sans ce retour visuel d'information sur la satisfaction de l'objectif, la tâche est vouée à l'échec.

Ainsi, une des difficultés de la conception de systèmes en interaction avec, ou modélisant, les milieux naturels est assez similaire : il est utopique de vouloir décrire complètement et exhaustivement toutes les situations que peut rencontrer le système que l'on conçoit et ainsi toutes les actions qu'il devrait réaliser. 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 (l'espace des états comprend trop de configurations) mais également parce que le savoir n'est pas forcément disponible sous une forme exploitable par les programmeurs et les algorithmes.

Demandons ainsi à un conducteur de four, par exemple le four de calcination de chamottes² que le groupe IMERYS nous a permis d'étudier, comment il règle la température et la vitesse de rotation. Nous aurons des réponses à propos de la consistance des dépôts sur le bord du four, sur des mesures d'humidité et d'autres paramètres, mais rien ne nous assure que d'autres informations ou traitements inconscients ne soient pas à l'œuvre dans le processus intelligent que réalise ce conducteur. Comment donc prendre en compte ces processus ?

Tentons également de modéliser le fonctionnement hydrologique d'un bassin versant hétérogène de montagne. À supposer que l'on connaisse les modèles physiques des multiples phénomènes permettant de réaliser la transformation de la pluie en débit dans la rivière, est-il

² La chamotte est une argile cuite à 1300°-1400° qui est utilisée pour réaliser des produits réfractaires.

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 du sous-sol, 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 perméabilité, sa porosité ?

L'apprentissage statistique apporte une réponse à ces questions. De même que l'asservissement exploite l'erreur entre la consigne et la sortie du système asservi, de même l'apprentissage automatique se fonde sur l'erreur du modèle par rapport à son objectif. 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.

Pour réaliser ce double travail, l'apprentissage statistique s'appuie sur des fonctions paramétrées lui permettant d'avoir la souplesse nécessaire pour s'ajuster à toutes les fonctions potentiellement étudiées. Nous verrons à ce propos à la section III.2 que les réseaux de neurones possèdent la propriété d'identification universelle.

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), ces paramètres permettent au modèle de s'ajuster parfaitement à l'ensemble d'apprentissage, et d'autant plus efficacement que le nombre de ces paramètres, ou la complexité du modèle, croît. Mais le modèle, si certaines précautions ne sont pas prises, peut alors être surajusté et tellement spécialisé par rapport à l'ensemble d'apprentissage qu'il apprendrait même la réalisation particulière du bruit dans cet ensemble et serait alors incapable de généraliser à d'autres ensembles. Le dilemme biais-variance, présenté au chapitre II.2 formalise ce phénomène. Plusieurs solutions ont été proposées pour l'éviter, parmi celles-ci, nous discuterons aux paragraphes III.5 et III.6 des méthodes de sélection de variable et de régularisation.

Appliquer l'apprentissage statistique à des phénomènes naturels complexes et partiellement connus, dont les variables sont mesurées avec une grande incertitude et sur des événements en nombre restreint, pose bien évidemment avec plus d'acuité le problème du surajustement. C'est pourquoi nos travaux sur la modélisation et la prévision des crues des bassins rapides nous ont conduits à revisiter ces méthodes de régularisation et de sélection des variables. La section III.8.a présente comment l'application rigoureuse de telles méthodes a permis le développement d'un outil de prévision des crues sur les bassins du piémont cévenol.

La "face noire" de l'identification universelle, qui est perçue de manière moins positive, est que la décomposition sur une base de fonctions paramétrées n'est pas très interprétable, au sens de la connaissance sur les phénomènes physiques ; c'est pourquoi ces modèles issus de l'apprentissage statistique sont qualifiés de "boîtes noires", et parfois décriés comme étant trop complexes à mettre en œuvre et "invérifiables".

Pourtant les modèles de type *boîte noire* extraient des bases de données une grande quantité d'information. Autant pour asseoir leur validité que pour exploiter cette information, certains travaux s'intéressent aux méthodes permettant de recouvrir cette connaissance ; ainsi les *boîtes transparentes* qui sont présentées dans ce mémoire en paragraphe IV.1 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. Cette méthodologie a été appliquée avec succès à des bassins versants particulièrement mal connus : bassins karstiques composés de roches carbonatées et fracturées, que l'eau a dissoutes selon des géométries de dimensions très variables et jusqu'en profondeur. Ces bassins hétérogènes sont le siège de crues, mais peuvent parfois jouer le rôle d'écrêteurs de crues ; ils sont également le principal réservoir en eau douce de la Terre.

Appliqué au bassin karstique de la source du Lez, source qui alimente en eau potable la ville de Montpellier, la méthode des *boîtes transparentes* a ainsi permis de mettre en évidence les propriétés hydrodynamiques de différents compartiments géologiques de ce bassin versant. Nos travaux futurs évoqués en IV.1.b.iii tenteront par ce moyen d'estimer les ressources en eau disponibles dans les karsts.

Enfin, si l'apprentissage statistique est capable de déterminer simultanément, et les paramètres et la fonction d'un modèle, il semble alors naturel, dans le contexte d'un environnement mal connu, de proposer des modèles adaptatifs c'est-à-dire qui continuent à apprendre durant leur fonctionnement. Ce type d'approche est évoqué au chapitre III.7, appliqué à l'apprentissage de comportement d'un robot hexapode par renforcement. Nous avons ainsi pu montrer que des tâches *a priori* difficiles à formaliser pouvaient être effectuées avec succès grâce à un apprentissage permanent effectué sur un modèle particulièrement simple.

Compte tenu de leur complexité, la connaissance imparfaite de leur état, ou des événements rares pouvant se produire, est également une propriété des systèmes météorologiques et hydrologiques. L'adaptativité (ou assimilation de données en météorologie) n'a-t-elle pas reçu ses lettres de noblesse lors de la grande tempête de 1999 ? Il pourrait en être ainsi au niveau des épisodes pluvieux extrêmes dont aucun enregistrement n'a encore été réalisé mais pour lesquels nous souhaiterions disposer d'un modèle capable de s'améliorer pendant que le phénomène se déroule. Une ouverture vers les travaux que nous envisageons dans le projet ANR FLASH est ainsi proposée à la section III.7.b.ii .

Ce mémoire, qui présente nos travaux sur l'application des réseaux de neurones à la modélisation des systèmes naturels complexes, ou des systèmes artificiels en relation avec un environnement naturel, n'est une présentation ni chronologique, ni exhaustive, car il n'est pas possible, tant pour des raisons pratiques que de confidentialité, de présenter tous les travaux et tous les projets de recherche industriels menés à bien ; elle se veut un cheminement sélectionné au travers de plus de quinze années de recherche.

Je vous propose de commencer la lecture par quelques considérations sur la méthode qu'utilise l'apprentissage statistique pour résoudre un problème à l'aide d'une fonction de coût et d'une base d'exemples, considérations qui introduisent certaines de nos préoccupations actuelles sur l'adéquation entre la fonction de coût, l'objectif de la modélisation et les distributions

statistiques des exemples. Nous nous intéresserons ensuite au dilemme biais-variance, que l'on pourrait présenter comme une formulation statistique du *principe du rasoir d'Occam*³, et qui conduit à sélectionner le modèle le plus parcimonieux afin d'assurer une bonne qualité de généralisation.

Restreignant alors notre propos aux réseaux de neurones dans la troisième partie de ce mémoire, nous pourrons présenter les modèles de prédicteur les plus adaptés à la modélisation des systèmes physiques qui nous intéressent particulièrement. L'apprentissage des modèles neuronaux sera évoqué, en particulier lorsqu'il est appliqué aux systèmes dynamiques ou pour concevoir des modèles adaptatifs. L'exemple de la synthèse d'un régulateur neuronal pour commander une pince électropneumatique sera alors présenté à titre d'illustration. Nous évoquerons ensuite les méthodes de régularisation et leur application aux modèles de prévision des crues rapides des bassins cévenols.

Complexes par nature, ces bassins versants du piémont cévenol n'ont rien de ce qui rend belle la physique : l'invariance d'échelle et la symétrie. Cumulant une géologie tourmentée, des pentes moyennes dignes du massif alpin et des orages aussi soudains qu'intenses, les crues qu'ils subissent peuvent gonfler les cours d'eau et, en quelques heures, les transformer en pièges mortels. La prévision a alors tout son sens : il faut anticiper avant que les réseaux routiers et de distribution ne soient coupés. Cette préoccupation passionnante est l'objet des projets BVNE et ANR FLASH que nous présentons ensuite.

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 tout l'enjeu évoqué dans la quatrième et dernière partie de ce mémoire. 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'un anthropisation des débits par un pompage intense et d'un bassin versant 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.

Au cœur de nos préoccupations, nous terminons ce mémoire en envisageant d'utiliser la méthode des boîtes transparentes, ainsi présentée, à l'estimation des réserves en eau stockée dans les karsts.

³ 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, on peut le comprendre comme une méthode d'élagage.

II. L'apprentissage statistique

APPRENTISSAGE PAR MINIMISATION DE FONCTION

a. *Maximum de vraisemblance et moindres carrés, autres fonctions de coût*

Comme nous l'avons indiqué dans l'introduction de ce mémoire, l'apprentissage statistique est fondé sur la minimisation d'une erreur, appelée dans la suite de ce mémoire fonction de coût. Cette dernière est formulée de manière à satisfaire un objectif, par exemple l'objectif d'avancer pour un robot adaptatif. L'objectif peut également être exprimé sous la forme d'une base d'exemples comprenant les variables d'entrée du processus à identifier et les réponses mesurées associées. La fonction de coût généralement choisie, mais pas seulement, est l'erreur quadratique. Outre ses bonnes propriétés de continuité et de dérivabilité, cette fonction est également particulièrement intéressante lorsque l'on dispose de bases de données dont les erreurs de mesure sont indépendantes et distribuées selon la loi gaussienne. En effet, dans cette configuration, W. H. Press (*Press et al*, 1992) présente comment le fait de poser l'hypothèse intuitive du maximum de vraisemblance est équivalent à minimiser l'erreur quadratique.

Ainsi, la nécessité de transformer les variables pour les "normaliser" (de manière à ce qu'elles soient centrées et réduites) avant de réaliser l'apprentissage est couramment admise. Or comme nous le présenterons chapitre III.8.a, les erreurs et approximations réalisées sur les acquisitions de variables naturelles, en particulier les variables météorologiques et hydrologiques ne vérifient aucune des deux hypothèses de l'indépendance et de la distribution gaussienne, comme nous pouvons l'illustrer sur la Figure 1 pour cette dernière caractéristique, sous l'hypothèse que le bruit de mesure est proportionnel à la grandeur de la variable. Nous avons d'ailleurs pu observer que lorsque l'apprentissage est réalisé sur des variables de pluie et de débit centrées et réduites, le modèle obtenu n'est pas le plus performant, et que la simple transformation consistant à effectuer un changement d'échelle des variables afin que leurs valeurs soient plus petites que un conduit à des modèles plus efficaces (Toukourou, 2007).

Cette difficulté est appréhendée par la communauté des modélisateurs en hydrologie. G. J. Bowden de son coté (Bowden, 2003) a étudié quelques transformations, linéaires et non linéaires, effectuées sur les variables de précipitation et de débit afin de diminuer leur grande variabilité sans noter d'améliorations notables alors que K. P. Sudheer (Sudheer, 2003) au contraire, note des améliorations notables sur l'estimation des pics de crue lorsqu'il applique des transformations sur les signaux de débit afin de diminuer les moments d'ordre trois et quatre. Dans les deux cas ces travaux, un peu anciens, utilisant la rétropropagation comme règle d'apprentissage et n'appliquant pas toujours de méthode de régularisation (section III.6) méritent d'être ré-explorés.

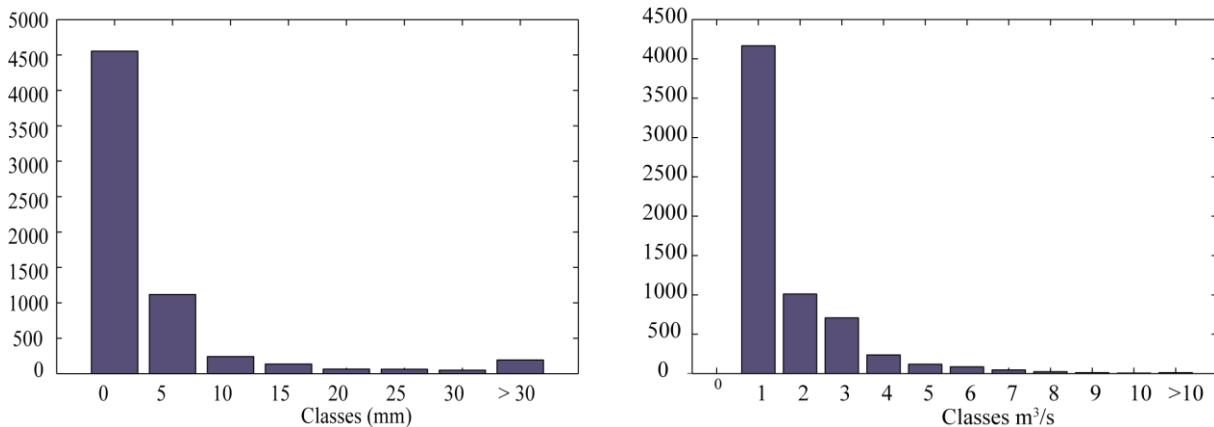


Figure 1. Distribution statistique de variables journalières de 1987 à 2005.
Précipitations enregistrées à St Martin de Londres (mm) à gauche et débits à la source du Lez (m^3/s) à droite.

b. Critères de performance

i. Des critères adaptés à l'objectif

A défaut de pouvoir déterminer une fonction de coût prenant en compte les particularités statistiques des signaux hydrologiques, les auteurs se focalisent plutôt sur les critères de sélection des modèles. Ainsi le choix d'un critère de sélection de modèle représentatif de l'objectif est souvent discuté. P. K. Kitadinis (Kitadinis *et al*, 1980) ont proposé le critère de persistance adapté particulièrement à la prévision ; dans d'autres études, la racine carrée de la valeur absolue de l'erreur est utilisée pour mesurer plus particulièrement les erreurs de faibles débits ; tandis que M. Toukourou a proposé, dans ses travaux sur la prévision des crues du Gardon d'Anduze, un critère prenant en compte plus spécifiquement la montée du pic de crue (Toukourou, 2009-b). C. Perrin dans sa thèse (Perrin, 2000) discute d'un grand nombre de critères et propose une stratégie multi-critères de sélection de modèle. R. Moussa (Moussa, 2010) s'inscrit dans la même démarche et dérive plusieurs critères du coefficient de détermination R^2 , ou critère de Nash (Nash *et al*, 1970) en modifiant le modèle de référence⁴ de ce dernier, terme qui apparaît dans le coefficient de réduction présent au dénominateur.

⁴ Le coefficient de détermination pour un signal exprimé en fonction du temps discret k : $s(k)$, s'écrit de la manière suivante : $R^2 = 1 - \frac{EQM}{\sum_{n \text{ échantillons}} (s(k) - r(k))^2}$. EQM est l'erreur quadratique moyenne et le modèle de

référence apparaît sous la forme de $r(k)$. Pour le coefficient de détermination, la valeur utilisée de $r(k)$ est la moyenne observée sur l'ensemble des n échantillons considérés. Cependant, on peut tout à fait prendre en compte d'autres modèles de référence. Ainsi, le critère de persistance n'est autre que le coefficient de détermination calculé à l'horizon de prévision h_p , prenant comme modèle de référence la *prévision naïve*, c'est-à-dire la prévision qui suppose que le système évolue très peu : $r(k)=r(k+h_p)$ où h_p est l'horizon de temps auquel s'effectue la prévision.

ii. Vers l'ajustement de la fonction de coût à l'objectif

Si de nombreux critères de performance ont été proposés, en revanche il existe moins d'initiatives visant à adapter la fonction de coût à l'objectif particulier du modèle. Ceci est dû au fait que la grande majorité des travaux s'intéresse à des processus dont les variables peuvent être considérées comme gaussiennes, rendant de ce fait l'erreur quadratique tout à fait adaptée. Comme présenté précédemment, cette hypothèse n'étant pas satisfaisante pour un grand nombre de systèmes hydrologiques, nous pensons travailler de manière conjointe les deux aspects de la question : d'une part les transformations visant à rendre gaussiennes les répartitions statistiques des variables d'entrée et de sortie et d'autre part l'utilisation d'autres fonctions de coût que l'erreur quadratique durant l'apprentissage.

Ainsi, dans le cadre du projet ANR FLASH (section III.8.a) Audrey Bornancin-Plantier étudie l'impact de l'utilisation d'un critère favorisant les valeurs les plus élevées du signal dans le calcul de l'apprentissage. Ce critère est inspiré du critère PWRMSE (Peak Weighted Root Mean Square Error) qui s'exprime ainsi :

$$PWRMSE = \sqrt{\frac{\sum_{n \text{ éléments}} (y^p(k) - y(k))^2 \left(\frac{1}{2} + \frac{y^p(k)}{2\bar{y}^p}\right)}{n}}$$

où $y^p(k)$ est la variable de sortie observée sur le processus à l'instant discret k , $y(k)$ la variable estimée par le modèle, n le nombre d'échantillons sur lequel est évalué le modèle et \bar{y}^p est la valeur moyenne de la grandeur observée.

Cependant pour simplifier les calculs de l'apprentissage⁵, le critère de pic que nous avons implémenté et qui est en cours d'évaluation s'exprime sous la forme :

$$PWMSE = \frac{1}{n} \sum_{n \text{ éléments}} (y^p(k) - y(k))^2 \left(\frac{1}{2} + \frac{y^p(k)}{2\bar{y}^p}\right)$$

L'erreur quadratique calculée à l'instant discret k est donc amplifiée si la valeur observée à cet instant est supérieure à la moyenne des valeurs observées (\bar{y}^p).

Suivant l'analyse proposée par R. Moussa et présentée précédemment, d'autres fonctions de coût pourront être étudiées, par exemple celle qui prend comme modèle de référence le modèle linéaire correspondant au modèle étudié (ayant les mêmes variables d'entrée et le même jeu de données) afin de mesurer le gain apporté par la non linéarité du modèle.

⁵ Lors du calcul de l'apprentissage, la dérivée de la fonction de coût est calculée à la présentation de chaque exemple ; ces dérivées sont ensuite cumulées pour estimer le gradient de l'erreur total qui est utilisé pour modifier les paramètres du modèle. Or, lorsque la fonction de coût comporte la racine carrée des erreurs quadratiques, la dérivée globale n'est plus la somme des dérivées individuelles de chaque exemple. Afin de conserver cette propriété d'additivité des gradients et comme la racine carrée n'est utile que pour conserver la dimension de l'erreur, nous avons préféré enlever cette dernière de la formule du critère de pic.

II.2. Dilemme biais-variance

a. Présentation

La conception d'un modèle par apprentissage statistique comporte, comme nous l'avons souligné précédemment, le choix de la fonction de coût que le modèle doit minimiser à partir d'un ensemble d'exemples. Dans le cas d'une fonction de coût quadratique, les m observations disponibles de la grandeur à modéliser $y^p(k)$ sont vues comme les réalisations d'une variable aléatoire Y , fonction de \mathbf{x} (le vecteur des variables d'entrées), telle que :

$$Y(\mathbf{x})=g(\mathbf{x})+B$$

$g(\mathbf{x})$ est la fonction de régression, elle est égale à l'espérance mathématique de Y conditionnée à \mathbf{x} : $g(\mathbf{x})=E(Y|\mathbf{x})$ et B est une variable aléatoire d'espérance mathématique nulle et de variance σ^2 représentant le bruit compris dans les observations.

Le but du modèle construit par apprentissage statistique est d'estimer la fonction $g(\mathbf{x})$ par une fonction $\hat{g}(\mathbf{x})$, au mieux, compte-tenu des observations disponibles. L'erreur de prédiction théorique réalisée par le modèle est donc l'espérance mathématique $E[(g(\mathbf{x})+B-\hat{g}(\mathbf{x}))^2]$. S. Geman (Geman *et al.*, 1992) a montré que cette erreur peut s'exprimer sous la forme de la somme de trois termes :

$$E[(g(\mathbf{x})+B-\hat{g}(\mathbf{x}))^2]=\sigma^2+E[(g(\mathbf{x})-\hat{g}(\mathbf{x}))^2]=\sigma^2+(g(\mathbf{x})-E[\hat{g}(\mathbf{x})])^2+E[(\hat{g}(\mathbf{x})-E[\hat{g}(\mathbf{x})])^2]$$

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 la régression théorique, tandis que le troisième terme est la *variance*, il rend compte de la variance de la prédiction, en fonction des modèles obtenus avec tous les ensembles d'apprentissage possibles.

Le biais correspond à l'ajustement du modèle aux données d'apprentissage et la variance est la variabilité de la prédiction obtenue en fonction de ces différents ensembles.

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

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

Il convient de noter que ces considérations sont théoriques et ne sont assurées que de manière asymptotique, pour les très grands ensembles de données. La régression $g(\mathbf{x})$ n'étant pas

connue, il n'est pas possible de calculer numériquement le terme de biais. De même, il n'est pas envisageable d'effectuer le calcul des modèles pour tous les ensembles d'apprentissage possibles.

Néanmoins, nous pensons intéressant d'illustrer le dilemme biais-variance sur un système hydrologique particulier, ceci est présenté dans la section suivante.

b. Illustrations pour un système dynamique

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, 1999), nous avons souhaité calculer ces grandeurs sur un exemple de modélisation du 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 a été aimablement fournie par Monsieur Alain Mangin et 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. Plus d'informations sur le bassin versant et les modélisations réalisées sont présentés en section III.8.b et dans (Johannet, 2008-b et Johannet, 2010). 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, 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 : $(y^p(\mathbf{x}) - \text{Moy}_{\mathcal{A}}[y(\mathbf{x}, \mathcal{A})])^2$
- Variance : $\text{Moy}_{\mathcal{A}}[(y(\mathbf{x}, \mathcal{A}) - \text{Moy}_{\mathcal{A}}(y(\mathbf{x}, \mathcal{A})))^2]$

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

On pourra trouver en Figure 2 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 al*, 1999). La première remarque peut être expliquée par les progrès faits depuis dans les algorithmes d'apprentissage. Pour la seconde constatation, nous pensons que le biais est très important dans les applications hydrométéorologiques du fait des grandes incertitudes et bruits sur les mesures (III.8) ; de ce fait, l'approximation du terme $g(\mathbf{x})$ par $y^p(\mathbf{x})$ est vraisemblablement assez inexacte.

On peut noter de plus sur cette illustration que le biais décroît bien au début tandis que la variance augmente globalement régulièrement en fonction de la complexité. Si la diminution du biais est rapide au début, en revanche ce dernier oscille pour les valeurs moyennes de complexité puis se met à augmenter pour les complexités élevées. Nous pensons que ce comportement du biais est dû aux incertitudes et au bruit de mesure qui l'entachent vraisemblablement d'une erreur liée à la variance σ^2 (variable aléatoire B).

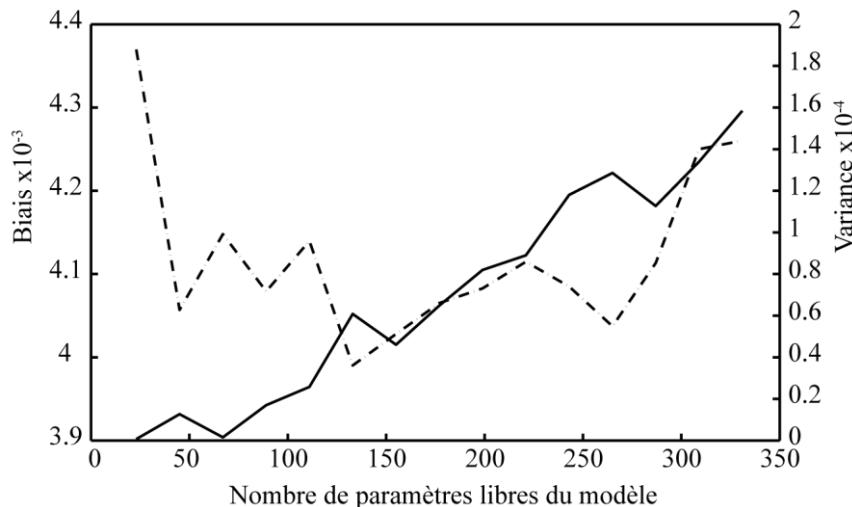


Figure 2 : Evolution du biais (trait pointillé) et de la variance (trait continu) en fonction du nombre de paramètres libres du modèle.

III. Les réseaux de neurones

III.1. Modèles de neurones et d'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 :

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

Le neurone formel effectue deux actions :

- le calcul de son *potentiel*, ou somme pondérée de ses variables d'entrée par ses paramètres :
 $v=\mathbf{x}^t \boldsymbol{\theta}$,
- le calcul de sa sortie 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).

Dans ce mémoire nous nous contenterons d'utiliser les trois fonctions d'évaluation : linéaire, tangente hyperbolique (ou sigmoïde) et seuil, car elles permettent de mettre en œuvre tous les modèles que nous utilisons, d'autres fonctions d'évaluations ont été étudiées et utilisées (ondelettes, spline) qui n'apportent pas d'avantage significatif dans la qualité des modèles.

Grace aux modèles de neurones précédemment définis, un réseau de neurones peut être conçu au moyen d'un graphe de connexions que l'on appelle architecture. Parmi toutes les architectures proposées, le réseau appelé perceptron multicouche sera particulièrement utilisé ; nous l'appellerons dans la suite plus simplement *réseau multicouche*. Ce réseau est composé d'une couche de neurones non linéaires de type sigmoïde, dite *couche cachée* car il n'y a pas de grandeur observée correspondant aux sorties de ces neurones, et d'une couche de sortie. Si le réseau de neurones est utilisé en identification de fonction, la fonction d'évaluation du neurone de sortie est linéaire. Ce dernier décompose alors la fonction qu'il effectue sur la base des sigmoïdes des neurones cachés. Si le réseau de neurones doit effectuer une fonction de classification⁶, alors le neurone de sortie peut être de type sigmoïde. Il permet donc de prendre une décision ainsi qu'une fonction logistique le fait en régression.

⁶ La fonction de *classification* consiste à affecter des éléments décrits par des variables à une classe en sortie. La classe est explicitée par un code discret. Cette fonction est à distinguer de l'*identification* qui consiste à associer les variables d'entrée d'un processus à la sortie continue observée de ce processus.

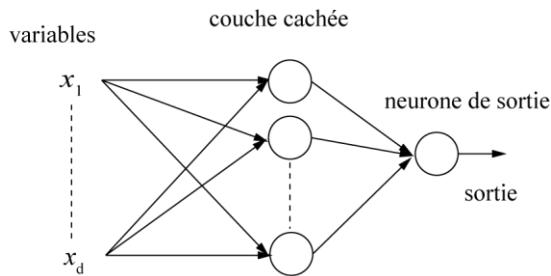


Figure 3 : Réseau Perceptron Multicouche

Notons que le réseau tel que représenté en Figure 3 ne possède pas de rétroaction de sa sortie vers ses entrées il est donc appelé *réseau statique*. Dans le cas où les variables sont des signaux échantillonnés, les réseaux statiques sont des filtres numériques transverses non linéaires.

III.2. Identification universelle et parcimonie

K. Hornic *et al.* ont démontré que le perceptron multicouche possédait la propriété d'approximation universelle (Hornic *et al*, 1989). C'est-à-dire que toute fonction $g(\mathbf{x})$, à valeurs bornées dans un domaine défini, peut être approchée à la précision ε près dans ce domaine par un réseau de type multicouche possédant un nombre fini de neurones cachés. C'est sur cette propriété que nous fondons le choix d'utiliser le perceptron multicouche pour identifier les relations non linéaires des systèmes naturels que nous étudions. Il est cependant bien évident que la démonstration de l'approximation universelle est une preuve d'existence de la solution, la capacité à trouver la solution dépendra tout autant de la base des informations disponibles et de la méthode de calcul des paramètres que de la capacité à sélectionner la complexité optimale au sens du dilemme biais-variance ; ces éléments sont repris à la section III.6 de ce chapitre.

Une autre propriété des réseaux multicouches est la *parcimonie*. Celle-ci s'apprécie en regard du nombre de paramètres nécessaires à l'identification d'une fonction non linéaire par un réseau multicouche d'une part, et par d'autres décompositions sur des fonctions à base de polynômes, spline et fonctions trigonométriques d'autre part. A. R. Barron (Barron, 1993) a montré que le nombre de paramètres, pour une précision donnée croît exponentiellement avec le nombre de variables pour les modèles *linéaires* en leurs paramètres tandis que ce nombre croît linéairement pour les modèles *non linéaires* en leurs paramètres. Or, la fonction implementée par le réseau multicouche dépend non linéairement de ses paramètres (la sigmoïde s'applique au potentiel des neurones), de ce fait ces modèles sont plus parcimonieux que les identificateurs linéaires en leurs paramètres (telles les décompositions sur fonctions spline, trigonométriques ou polynômes). De plus, cette propriété de parcimonie est d'autant plus significative que le nombre de variables est grand.

On pourra noter que le nombre de paramètres d'un réseau multicouche augmente très rapidement avec le nombre de neurones cachés et/ou le nombre de variables. Ce nombre est sans commune mesure avec le nombre de paramètres d'un modèle physique dédié à la même fonction. Rappelons à ce propos que le perceptron multicouche, au contraire d'un modèle physique, doit déterminer simultanément et le type de fonction du modèle et les paramètres physiques, même si ces derniers ne sont pas identifiables en tant que tels dans le réseau. On ne

peut donc comparer la complexité des deux types de modèles au regard de leur seul nombre de paramètres ajustables.

III.3. Réseaux dynamiques

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

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

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

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

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

où 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 $x(k)$ et comme variable d'état $y(k-1)$.

O. Nerrand (Nerrand *et al*, 1993) ont présenté comment la connaissance que l'on a des perturbations et bruits opérant sur le modèle postulé récurrent d'un processus peut être prise en compte pour synthétiser un prédicteur optimal.

a. Modèles de prédicteur optimal

Si nous limitons notre propos aux modèles de type entrée-sortie pour lesquels le vecteur d'état est composé des valeurs passées de la sortie. 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 physique étudié, $y(k)$ la sortie de cette représentation, $\mathbf{u}(k)$ le vecteur des variables exogènes, r et w sont des entiers positifs.

Ce modèle postulé peut être représenté schématiquement tel qu'en Figure 4.

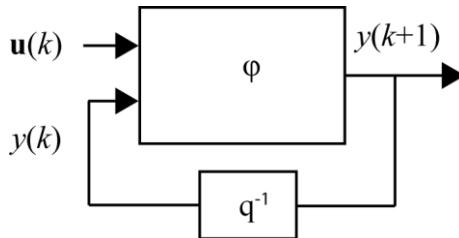


Figure 4 : Modèle postulé récurrent.

Le modèle postulé reçoit en entrée les variables exogènes à l'instant k (vecteur $\mathbf{u}(k)$) et la sortie précédente $y(k)$; sa sortie est $y(k+1)$. q^{-1} est l'opérateur retard.

i. *Hypothèse bruit de sortie*

Le modèle postulé peut être soumis à des perturbations additives sur sa sortie, correspondant par exemple à un bruit de mesure. Ceci se traduit par la relation :

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

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

Le modèle postulé correspondant à l'hypothèse bruit de sortie est représenté en Figure 5.a, son état $\mathbf{y}^s(k)$ n'est pas affecté par les perturbations et est donc bouclé pour estimer l'état futur. En revanche, comme la sortie mesurée $y^p(k+1)$ est entachée d'erreur, on évite de l'utiliser dans l'estimation des sorties futures.

Le modèle neuronal correspondant à ce modèle postulé est donc un modèle récurrent qui s'écrit ainsi :

$$y(k+1) = g_{rn}(y(k), \dots, y(k-r+1), u(k), \dots, u(k-w+1), \boldsymbol{\theta})$$

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

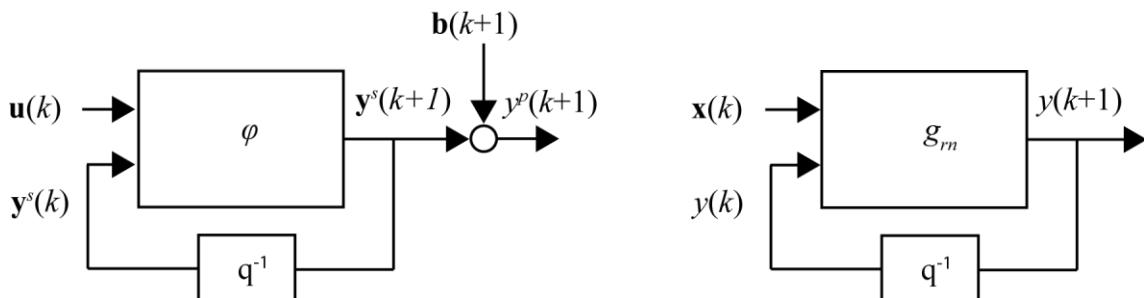


Figure 5 : Modèle postulé (5.a) et prédicteur associé (5.b) à l'hypothèse bruit de sortie.

Si la fonction g_{rn} parvient à identifier parfaitement la fonction φ , le réseau de neurones récurrent est stable, si l'on dispose de plus des valeurs exactes des perturbations pour initialiser

la fonction g_m , alors on montre que le prédicteur réalise la meilleure prédiction possible : $y^p(k+1)-g_m(k)=b(k+1)$ (Dreyfus, 2008). Toute la part déterministe du phénomène est identifiée par la fonction g_m .

Le prédicteur ainsi obtenu peut effectuer des prévisions pour un horizon indéfini à condition de disposer des prévisions de ses variables exogènes. 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 estimés ou des niveaux de nappe.

Dans la thèse de Line Kong A Siou, nous avons mis en œuvre ce prédicteur pour estimer les débits et la piézométrie de la source du Lez. Ce travail en cours est effectué en collaboration avec P. Fleury et N. Dorfliger de l'équipe du BRGM⁷ de Montpellier pour comparer les propriétés des deux modèles : d'une part un modèle à réservoirs (P. Fleury *et al*, 2008) et d'autre part le prédicteur récurrent à réseau de neurones.

ii. Hypothèse bruit d'état

Dans l'hypothèse *bruit d'état* le modèle postulé est soumis à des perturbations additives sur son état. Cette hypothèse correspond au modèle NARX (Non linéaire Auto-Régressif à entrées exogènes). La relation entrées-sortie du modèle postulé s'écrit :

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

où $y^p(k+1)$ est la grandeur observée du processus, sortie de cette représentation, $b(k+1)$ est un bruit d'état agissant à l'instant $k+1$, φ est une fonction, $u(k)$ le vecteur des variables exogènes, r et w sont des entiers positifs.

Le modèle postulé correspondant à cette représentation est représenté en Figure 6.a.

Compte tenu du modèle postulé, le modèle neuronal correspondant à cette représentation n'est pas un modèle récurrent puisque ses variables sont les entrées exogènes et les sorties observées du processus ($y^p(k)$). Comme son état est bruité il est en effet plus intéressant d'appliquer en entrée les variables observées du processus. Le prédicteur associé s'écrit donc :

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

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

⁷ Le BRGM : Bureau de Recherches Géologiques et Minières est l'établissement public français de référence dans le domaine des sciences du sol et du sous-sol.

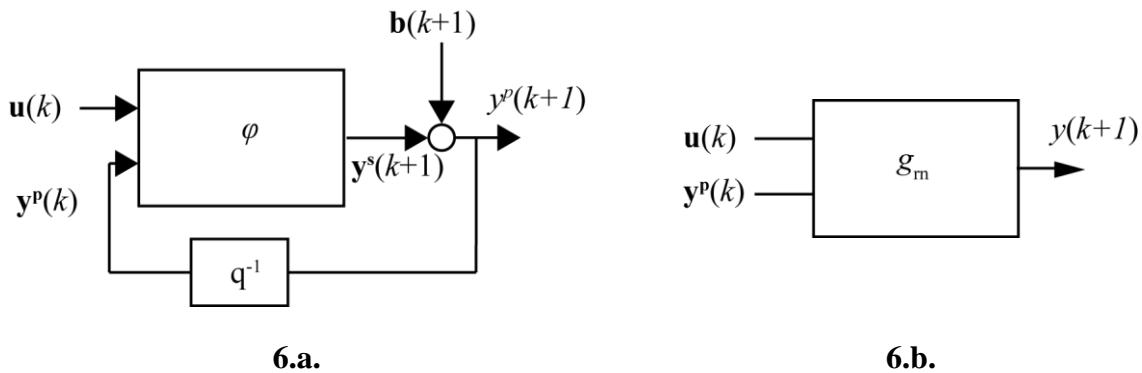


Figure 6 : Modèle postulé (6.a) et prédicteur associé (6.b) à l'hypothèse bruit d'état.

Si la fonction g_m identifie parfaitement la fonction φ du modèle postulé, alors le prédicteur neuronal est tel que : $y^p(k+1)-g_m(k+1)=b(k+1)$, le prédicteur a identifié toute la partie déterministe du processus et son erreur est limitée à celle du bruit d'état non mesurable.

Même si ce prédicteur a vocation à simuler un système dynamique, on peut remarquer qu'il n'est pas récurrent. Comme il est alimenté par les sorties mesurées du processus, ce prédicteur est appelé *dirigé* par le processus, par opposition au prédicteur NARX qui est qualifié de *non dirigé*.

En pratique, ce prédicteur dirigé est celui qui délivre les meilleures prévisions sur les crues comme nous le présenterons en section III.8 de ce chapitre. Ce dernier point pourrait laisser à penser que les principales erreurs interviennent donc sur l'estimation de l'état du processus.

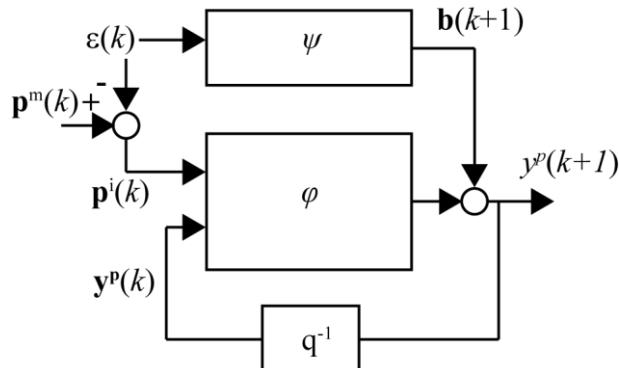


Figure 7 : Représentation des erreurs de mesures des entrées exogènes, vues comme une perturbation additive sur l'état.

D'autre part, on peut considérer les perturbations additives sur l'état comme des perturbations de mesure des entrées exogènes agissant sur l'état après un filtrage par une fonction ψ inconnue. Ainsi, comme représenté en Figure 7, l'erreur de mesure $\varepsilon(k)$ commise sur les précipitations parfaites $p^i(k)$ est filtrée par la fonction inconnue ψ puis s'additionne à l'état du processus. Les précipitations mesurées $p^m(k)$ s'expriment comme la somme des précipitations parfaites $p^i(k)$ et de l'erreur $\varepsilon(k)$.

Une perturbation additive sur l'état peut donc être vue comme une perturbation opérant sur les variables d'entrée du modèle hypothèse. On comprend aisément que si les entrées sont imparfaites, le prédicteur associé a avantage à capitaliser sur les sorties mesurées du processus.

III.4. Apprentissage

L'apprentissage consiste à estimer les paramètres Θ du réseau de neurones afin de minimiser un critère préalablement défini. Comme présenté précédemment, en général ce critère est 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 seconde de la fonction de coût.

a. Apprentissage des systèmes dynamiques

Quand le modèle de réseau est récurrent, comme par exemple le prédicteur associé au modèle postulé bruit de sortie (Figure 5.b.), il est avantageux d'effectuer l'apprentissage sur la forme canonique du modèle bouclé (Nerrand *et al*, 1993). En effet, cette dernière représentation considère le modèle sous la forme d'une partie acyclique (ou statique) et d'une partie comportant les retards, déportée à l'extérieur du réseau. Ainsi la prise en compte du temps dans le réseau se fait en coupant la boucle des retards et en dupliquant le réseau en autant de *copies* que l'on souhaite remonter dans le passé. Le perceptron multicouche ainsi dupliqué en c copies possède donc $2c$ couches de paramètres à identifier. Néanmoins, comme il s'agit du même réseau qui est dupliqué, *in fine* ce dernier, en phase de prédiction, ne possède pas plus de paramètres. Pour cela, durant l'apprentissage, à l'issue de chaque modification des paramètres, la moyenne de chaque paramètre est effectuée sur toutes les copies. Cette technique est appelée la technique des *poids partagés*.

La méthode est illustrée en Figure 8 dans le cas particulier de deux copies. Les variables exogènes, représentées par le vecteur $\mathbf{u}(k-c)$ sont appliquées à chaque copie, la sortie de la copie $y(k-c)$ est appliquée en variable d'entrée de la copie suivante. La dynamique du processus peut ainsi être prise en compte.

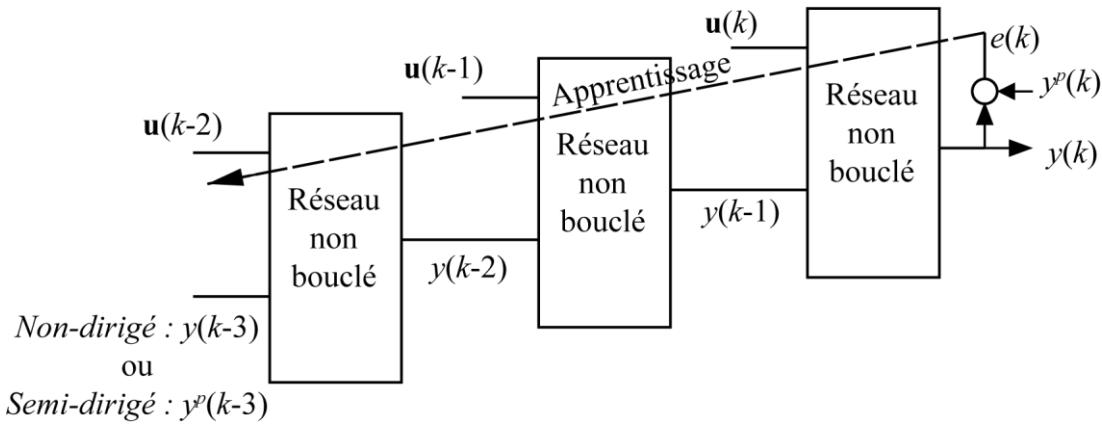


Figure 8 : Apprentissage d'un réseau dynamique avec la méthode des copies.

Se pose la question de l'initialisation de la copie correspondant au temps le plus ancien. Si les valeurs observées du processus sont disponibles, on peut initialiser cette première copie avec ces valeurs, on dit que l'on est alors en mode *semi-dirigé*. Dans le cas contraire, comme nous l'étudions pour la prévision des crues sur les bassins-versants non jaugés dans le cadre de la thèse de Guillaume Artigue qui est présentée en section III.8 de ce chapitre, on parle de mode *non-dirigé*. Dans ce dernier cas, les valeurs observées ne sont pas disponibles.

Comme nous l'avons indiqué, l'apprentissage est réalisé de manière itérative. Les paramètres du modèle sont initialisés aléatoirement au début de l'apprentissage, l'erreur commise y est donc importante. Lorsque le modèle est statique, cette erreur n'est pas rebouclée vers l'entrée du modèle, l'apprentissage peut donc continuer d'améliorer le prédicteur. Lorsque le modèle est récurrent, l'erreur est, au contraire, réintroduite dans le modèle et peut même conduire à la divergence de l'apprentissage. Pour limiter cette erreur au début de l'apprentissage on peut donc utiliser le mode semi-dirigé qui permet de prendre en compte la dynamique du modèle tout en limitant cette erreur de début d'apprentissage.

b. Illustration : synthèse de l'asservissement d'une pince électropneumatique

Les deux types de prédicteurs évoqués dans les paragraphes précédents ont été mis en œuvre dans un travail effectué avec mon collègue Pierre Couturier. Il s'agissait d'asservir une pince composée de deux doigts rigides mis en rotation par un actionneur pneumatique⁸ (Figure 9). Ce type de préhenseur est assez utilisé dans les tâches de micromanipulation en robotique. Du fait des non linéarités dues à la conception mécanique et à la compression du gaz, l'asservissement en position de manière précise est assez difficile à réaliser. Dans les années 1990, il était donc intéressant d'évaluer les potentialités de l'apprentissage statistique dans ce domaine.

⁸ Nous remercions Monsieur Hugues Silvain pour la conception et réalisation de la pince électropneumatique.

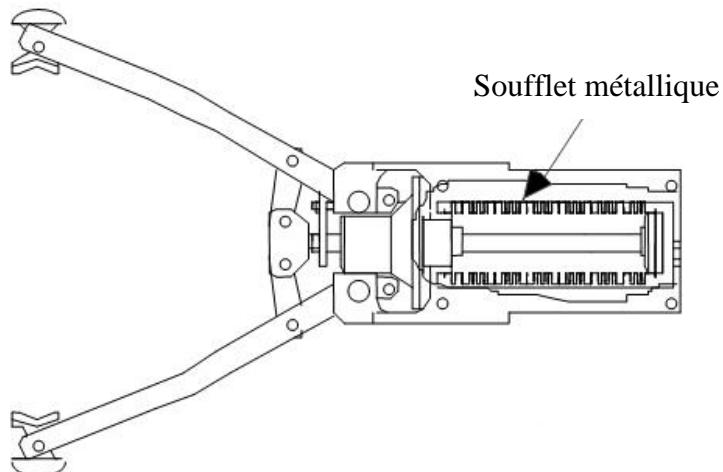


Figure 9 : Schéma de la pince électropneumatique
La pince est longue de 300 mm et a une ouverture de 150 mm.

La synthèse d'un asservissement pose une question différente de celle de l'identification d'un processus. Considérons le schéma classique d'un asservissement comportant un système à asservir, un *correcteur* et le signal de *consigne* ($y^c(k)$) qui représente la valeur que doit atteindre la sortie du processus à chaque instant (Figure 10).

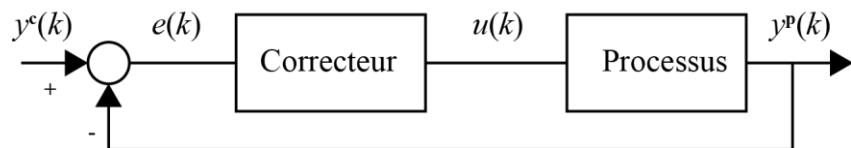


Figure 10 : Schéma élémentaire d'un asservissement

Le correcteur reçoit en entrée la différence $e(k)$ entre la sortie du processus et la sortie désirée (*consigne*) et traite cette différence de manière à conduire le processus à se rapprocher de la valeur de consigne. Le correcteur, ou contrôleur dont la sortie fournit le signal de *commande* $u(k)$ doit assurer à la fois la *stabilité* du système asservi et la *précision* dans la satisfaction de la consigne. Il peut également imposer des *contraintes dynamiques* à l'asservissement (par exemple un temps de réponse fixé).

La synthèse d'un contrôleur par apprentissage statistique se heurte donc au fait que l'on ne connaît pas la valeur que doit avoir le signal de commande puisque le processus est en général non linéaire et non inversible. Néanmoins, la capacité des réseaux de neurones à identifier un processus non linéaire peut être mise à profit, en synthétisant un modèle du processus asservi non linéaire, pour disposer d'une estimation de ce signal de commande, permettant ainsi de réaliser l'apprentissage du correcteur. Ce type d'approche est qualifiée de commande *indirecte*, par opposition à la commande *directe* où le modèle du processus n'est pas demandé.

Le travail a ainsi consisté en plusieurs étapes, d'une part l'identification d'un modèle neuronal de la pince, ou *prédicteur*, et d'autre part la conception de plusieurs contrôleurs afin d'imposer

des dynamiques convenables tant en poursuite qu'en régulation⁹ pour un contrôle de la pression appliquée par la pince lors de la préhension d'une part, et de la position de la pince d'autre part.

Notons que lorsque le modèle prédictif du processus est utilisé dans le schéma de contrôle indirect, celui-ci permet d'anticiper sur l'erreur qui pourrait se produire dans le futur et, grâce au signal de commande, tendre à annuler cette erreur avant qu'elle ne se produise, on parle alors d'*anticipation* et de commande *prédictive*.

i. *Identification du processus*

La stratégie d'identification, plus amplement présentée dans (Couturier *et al*, 1998), peut se résumer ainsi :

- La fonction de coût intègre les erreurs quadratiques de la sortie estimée sur un horizon temporel de profondeur j . Cet horizon définit la limite supérieure de l'anticipation souhaitée pour le prédicteur.
- Le prédicteur est récurrent, il représente le processus de la pince dont les variables d'état peuvent être composées de sa sortie à l'instant k et aux instants précédents, ainsi que de variables d'état non mesurées. Dans le modèle, les variables d'état non mesurées correspondent à des neurones de « sortie », pour lesquels on ne dispose pas de valeur mesurée (Elmann, 1990).
- La méthode des copies est utilisée pour effectuer l'apprentissage sur la forme canonique du réseau de neurones et permet ainsi de prendre en compte la dynamique du système à identifier.
- Afin de disposer d'une base d'exemples variée permettant d'effectuer l'apprentissage, une séquence de consignes pseudo-aléatoires (en amplitude et en fréquence) est appliquée à la pince.
- L'ajustement de la complexité est réalisé de la manière suivante : le nombre de neurones cachés est augmenté à partir de un jusqu'à ce qu'aucune amélioration ne soit notée dans la généralisation.

Les modes d'apprentissage dirigé, semi-dirigé et non dirigés sont évalués pour initialiser les variables d'état qui correspondent au vecteur des sorties observées, tandis que le mode non dirigé est le seul qui permette de prendre en compte les variables d'état non mesurées (Figure 11).

Le réseau de neurones émule la pince par la fonction suivante :

$$y(k+1) = g_{rn}(y(k), \dots, y(k-r+1), s(k), \dots, s(k-e+1), u(k), \dots, u(k-w+1), \theta)$$

⁹ La poursuite consiste à imposer une trajectoire à la sortie du processus, tandis que la régulation ramène le dispositif vers la trajectoire en cas de perturbation. Les deux tâches peuvent avoir des dynamiques différentes et elles peuvent être dissociées en plusieurs contrôleurs différents.

où $\mathbf{y}(k)$ est le vecteur des sorties estimées par le réseau à l'instant k et aux instants précédents, $\mathbf{s}(k)$ le vecteur des variables d'état non mesurées à l'instant k et aux instants précédents, $\mathbf{u}(k)$ le vecteur des entrées exogènes à l'instant k et aux instants précédents et $\boldsymbol{\theta}$ le vecteur des paramètres du réseau.

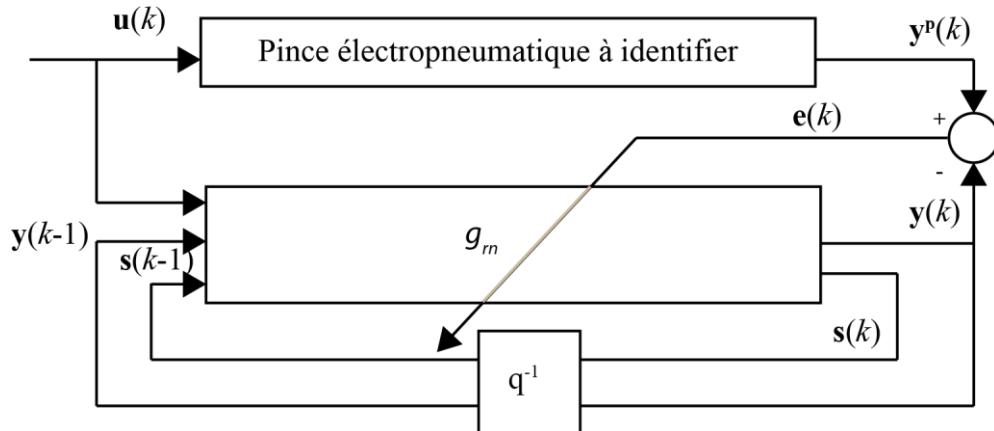


Figure 11 : Stratégie d'identification de la pince électropneumatique.
(Couturier, 1998)

Les résultats obtenus sont satisfaisants pour l'identification du déplacement, mais moins bons pour l'identification de pression du fait du frottement statique de la pince (Couturier *et al*, 1998). Néanmoins, on peut juger ses performances en prédition suffisantes sur l'horizon d'anticipation considéré.

ii. Contrôle de la pince électropneumatique

On souhaite que le système asservi se comporte comme un *modèle de référence* imposé, par exemple, comme un système linéaire du premier ordre (le modèle de remplissage du réservoir présenté en section III.3. est un modèle linéaire du premier ordre).

Comme soulevé précédemment, une des difficultés de la synthèse d'un contrôleur par apprentissage statistique est que l'on ne dispose pas de valeur désirée pour la sortie du contrôleur. A partir des schémas de contrôle proposés par M. Kawato (type direct), qui afin de disposer d'un contrôle opérationnel par un régulateur conventionnel dès le début de l'apprentissage utilise la sortie d'un correcteur conventionnel comme estimation de l'erreur de sortie du contrôleur neuronal (Gomi *et al*, 1993), et du schéma proposé par M. I. Jordan (type indirect), qui effectue l'apprentissage du contrôleur au travers¹⁰ du modèle neuronal du processus pour imposer une anticipation (Jordan *et al*, 1992), Pierre Couturier a proposé un schéma de contrôle général qui permet de synthétiser les deux types de schéma de contrôle pour le calcul du correcteur, récurrent ou non récurrent. Ce schéma est présenté dans (Couturier *et al*, 1998). Il inclut :

¹⁰ Lorsque l'on effectue l'apprentissage d'un réseau de neurones, la matrice Jacobienne (dérivées partielles des sorties du modèle par rapport aux entrées) est calculée par la règle de la rétropropagation. Si le réseau de neurones identifie correctement le processus, on peut considérer que la matrice Jacobienne calculée par le réseau est une estimation de celle du processus et l'on peut donc utiliser ces dérivées partielles pour réaliser l'apprentissage du correcteur placé en série avant le modèle du processus.

- Le prédicteur identifiant le processus (ici le modèle neuronal de la pince) qui réalise la fonction g_{rn} précédemment présentée (entrées $\mathbf{u}(k)$, $\mathbf{s}(k)$, $\mathbf{y}(k-1)$ et sortie $\mathbf{y}(k)$).
- Un bloc de contrôle qui comporte plusieurs correcteurs : linéaires et non linéaires par réseaux de neurones ; selon leurs entrées, les correcteurs non linéaires peuvent être dédiés à la tâche de régulation avec une dynamique propre, ou à la tâche de poursuite avec anticipation selon une autre dynamique.
- Les variables sélectionnées des différents correcteurs sont les mêmes que celles qui seraient utilisées par leur équivalent en commande linéaire.

Le schéma général de contrôle a été mis en œuvre pour les deux fonctions de contrôle de la pression dans la chambre de l'actionneur et de contrôle de la position de la pince. Les saturations matérielles ont également pu être prises en compte dans la loi de commande. Par exemple la loi de commande peut prendre en compte la valeur maximale autorisée de la commande et être ainsi écrêtée.

L'avantage de ce schéma général est également qu'il permet à l'apprentissage d'être effectué en ligne et que le modèle du processus n'a besoin d'être un bon prédicteur que sur la fenêtre temporelle limitée de l'anticipation.

En synthèse, ce travail a permis d'étudier les potentialités de l'apprentissage statistique pour identifier un système non linéaire dynamique et pour synthétiser des correcteurs, également non linéaires et récurrents, assurant une précision et une dynamique donnée. Si les performances dynamiques et en précision se sont montrées satisfaisantes et fort intéressantes (Couturier, 1997), en revanche les conditions de stabilité n'ont pu être exhaustivement délimitées, même empiriquement.

III.5. Sélection de variables

La sélection de variables consiste à choisir les variables effectives parmi l'ensemble des variables candidates proposées par les experts. Si l'on est capable de connaître les variables pertinentes pour la fonction à réaliser par apprentissage statistique, comme par exemple pour l'identification d'un modèle non linéaire de remplissage d'un réservoir (décris précédemment), on pourra sélectionner les mêmes variables. De plus, il se produit assez souvent le cas où les variables disponibles sont mutuellement dépendantes. Elles comportent le même type d'information, mais celle-ci est parfois mesurée au moyen de méthodes d'observation différentes. Afin de diminuer la complexité du réseau, il convient alors d'utiliser des méthodes de sélection de variables qui permettent de définir le réseau le plus parcimonieux et d'améliorer ainsi les performances de généralisation.

La sélection de variables nécessite de mettre en œuvre :

- Un critère quantitatif de performance qui sert à ordonner les variables. Pour ce faire des méthodes d'orthogonalisation du type de Gram-Schmidt, ou des méthodes heuristiques (Yacoub *et al.*, 2001) peuvent être utilisées.

- Un seuil à partir duquel les variables seront jugées non pertinentes ; on peut par exemple rejeter les variables qui influencent moins la sortie du modèle qu'une variable dont les valeurs sont tirées aléatoirement (Stoppiglia *et al*, 2003).

Comme les variables peuvent être corrélées il faudrait rigoureusement évaluer toutes les combinaisons possibles ce qui est matériellement impossible. L'ensemble des variables sélectionnées dépend alors en général de la procédure suivie et n'est donc pas unique : plusieurs sous-ensembles de variables peuvent conduire à des performances relativement équivalentes (Cybas *et al*, 1996).

III.6. Méthodes de régularisation

Comme nous l'avons signalé précédemment en section II.2 l'erreur estimée sur l'ensemble d'apprentissage est un mauvais estimateur de l'erreur de généralisation et cette dernière augmente en fonction de la complexité du réseau. Cependant, afin d'exploiter au mieux l'information contenue dans la base d'apprentissage dont on dispose, certaines méthodes ont été développées pour pallier ce phénomène : ce sont les méthodes de *régularisation*. Ces méthodes ont toutes pour objet de diminuer la variance. Parmi celles-ci on distingue les méthodes qui consistent à sélectionner les modèles qui ne sont pas surajustés des méthodes qui interviennent durant le calcul de l'apprentissage.

a. Régularisation par sélection de modèle

Avant toute sélection de modèle il est nécessaire de mesurer l'erreur de généralisation. Rappelons que celle-ci est calculée sur un ensemble d'exemples qui n'ont pas servi à l'apprentissage. Afin que cette erreur ne dépende pas du choix d'un sous-ensemble particulier, ce qui est possible si la base des exemples est de dimension réduite ou si quelques exemples correspondent à un phénomène rare ou extrême, la procédure de la validation croisée a été proposée (Stone, 1974).

Représentée schématiquement en Figure 12, la validation croisée consiste à diviser l'ensemble d'apprentissage en K sous-ensembles. Chacun est utilisé à son tour en validation, les autres sous-ensembles servant à effectuer l'apprentissage. Sur chacun des K sous-ensembles de validation, on calcule un score. Ainsi, à l'issue de la procédure qui consiste en K apprentissages successifs sur K sous-ensembles, on peut disposer d'un score de performance, estimé en validation, mais représentatif de l'ensemble de la base.

Le score généralement adopté est le score de validation croisée qui est la racine carrée de la moyenne des erreurs quadratiques de chacun des scores de validation J_K .

$$S = \sqrt{\frac{1}{K} \sum_K EQM}$$

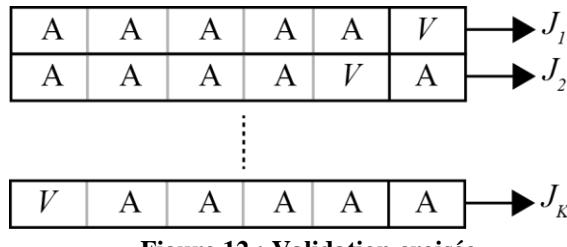


Figure 12 : Validation croisée

En fonction du critère choisi pour effectuer l'apprentissage, dont nous avons discuté en II.b, on gagnera en cohérence à utiliser le même critère pour l'apprentissage et pour calculer le score de validation croisée.

Dans l'idée de réduire la variance en diminuant la complexité du modèle, la validation croisée a été utilisée pour effectuer également la sélection de variables. En particulier sont conservées les variables qui améliorent le score de validation croisée et supprimées celles qui le dégradent. Ainsi nous avons sélectionné les fenêtres temporelles définissant l'historique des précipitations appliquées aux modèles d'hydrosystèmes (Toukourou *et al*, 2009-a), (Kong A Siou *et al*, 2011-b).

Lorsque nous nous sommes intéressés à la prévision des crues des rivières du Piémont Cévenol, nous avons introduit la *validation croisée partielle*, validation croisée qui opère sur les événements pluvieux les plus intenses de façon à sélectionner les modèles prenant le mieux en compte ces événements spécifiques (Toukourou *et al*, 2009-a).

b. Régularisation par diminution de la valeur des paramètres

On peut comprendre intuitivement qu'une variance importante peut provenir du fait que les paramètres ont des valeurs trop élevées, contribuant à des pentes fortes pour les sigmoïdes et donc à une sortie fortement variable en fonction de faibles variations de l'entrée (Bishop, 1995). C'est pourquoi plusieurs méthodes de régularisation ont pour objet de diminuer la grandeur des paramètres du réseau. Parmi celles-ci nous avons mis en œuvre la modération des poids et l'arrêt précoce.

La modération des poids consiste à modifier la fonction de coût de l'apprentissage en y intégrant un terme de pénalisation de la valeur des paramètres. On écrit alors :

$$J_r = (1 - \gamma)J + \gamma \|\boldsymbol{\theta}\|^2$$

où J_r est la fonction de coût intégrant la régularisation, J la fonction de coût sans régularisation (par exemple l'erreur quadratique moyenne), $\boldsymbol{\theta}$ le vecteur des paramètres et γ l'hyperparamètre qui permet d'ajuster de manière heuristique le poids relatif des deux termes.

Dans le même esprit, consistant à diminuer la valeur des paramètres, l'*arrêt précoce* interrompt l'apprentissage avant que le minimum de la fonction de coût ne soit atteint grâce à un ensemble d'exemples indépendants des exemples utilisés en apprentissage, appelé l'*ensemble d'arrêt*.

Lorsque l'on utilise l'arrêt précoce, au fur et à mesure du déroulement de l'apprentissage, l'estimation de la qualité de la généralisation est effectuée sur l'ensemble d'arrêt ; lorsque l'on

observe que la généralisation devient moins bonne (l'erreur observée sur l'ensemble d'arrêt augmente), l'apprentissage est arrêté. J. Sjöberg (Sjöberg *et al*, 1995) présente cette méthode comme une technique de régularisation car l'arrêt précoce interrompt l'apprentissage avant que les paramètres n'atteignent des valeurs trop importantes.

En pratique, l'utilisation de l'arrêt précoce sur les systèmes hydrologiques est assez délicate à effectuer car l'apprentissage est alors spécialisé par rapport à l'ensemble d'arrêt, qui ne peut être tiré au hasard dans la base des exemples disponibles, car le traitement des signaux temporels nécessite la continuité des signaux. Dans le travail de thèse de Mohamed Toukourou (Toukourou, 2009-b), nous avons pu noter de très fortes variabilités de la solution obtenue en fonction de l'ensemble d'arrêt choisi. Finalement la solution retenue a été de sélectionner en arrêt l'ensemble qui est le mieux estimé lorsqu'il se trouve en généralisation ; cet ensemble d'arrêt peut correspondre à un événement pluvieux particulier ou à un cycle hydrologique (1^{er} septembre d'une année au 31 août de l'année suivante). Ainsi, arrêter l'apprentissage en fonction de l'ensemble qui est le mieux prédit a une certaine cohérence puisque c'est celui qui représente le mieux l'ensemble d'apprentissage.

c. Avantages du couplage de plusieurs méthodes

Les méthodes de régularisation peuvent être utilisées simultanément. On peut utiliser l'arrêt précoce tout en sélectionnant les variables au moyen de la validation croisée.

Dans le travail de thèse de Line Kong A Siou, nous étudions l'impact de ces méthodes sur la qualité de la prévision des débits de la source du Lez (Hérault). En reportant le score de validation croisée en fonction de l'augmentation du nombre de neurones cachés nous comparons les performances respectives de l'arrêt précoce et de la modération des poids. Par exemple, on peut noter sur la Figure 13, (Kong A Siou *et al*, 2011-a) que les deux méthodes de régularisation dégradent légèrement la qualité de la prévision réalisée, mais permettent de prévenir avec une grande efficacité l'augmentation de la variance. Ainsi elles rendent le choix de la complexité beaucoup moins critique et permettent d'alléger considérablement le nombre d'expériences à réaliser pour concevoir un système opérant.

d. Vers un outil de compréhension du modèle

Nous avons indiqué précédemment que la sélection de la taille des fenêtres temporelles permettant de fixer l'historique des précipitations pris en compte dans les modèles de prévision des crues pouvait diminuer la complexité du modèle. La recherche de cette complexité optimale pourrait conduire à estimer des grandeurs hydrologiques fondamentales dans la compréhension du fonctionnement d'un bassin versant, comme le temps de concentration, le temps de montée ou le temps de réponse de ce bassin versant. Si ces deux dernières durées sont aisées à définir sur un système artificiel dont on maîtrise les entrées, en revanche, toutes sont très difficiles à appréhender pour un bassin versant rapide comme celui du Gardon d'Anduze que nous étudions dans les thèses de Guillaume Artigue et de Audrey Bornancin-Plantier du fait du caractère pseudo-aléatoire des précipitations. Ainsi, comme chacune des méthodes de régularisation conduit à un dimensionnement différent des fenêtres temporelles, nous cherchons à déterminer laquelle de ces méthodes conduit à un modèle physiquement interprétable, ceci permettrait

alors d'une part de mieux comprendre le modèle et d'autre part d'obtenir de la connaissance sur le bassin versant considéré.

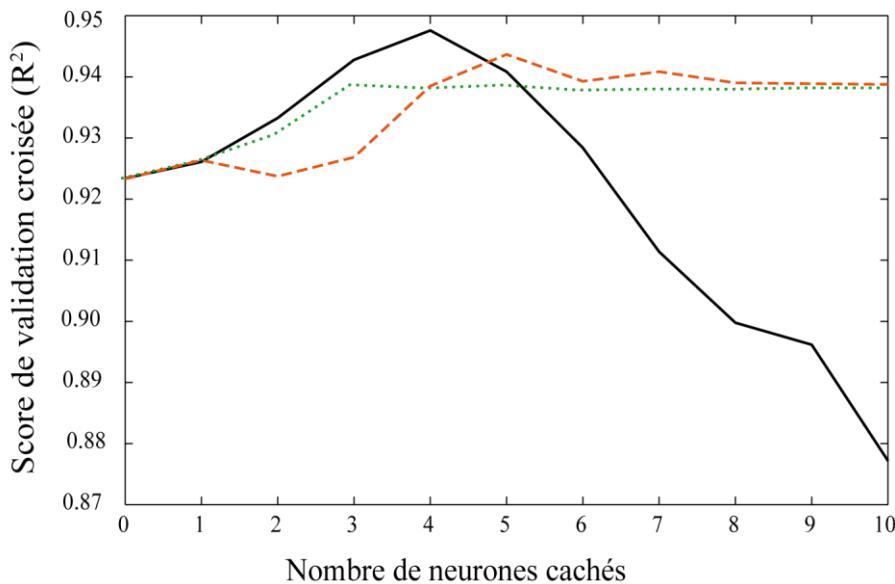


Figure 13 : Illustration de l'évolution du score de validation croisée (ici fondé sur le R^2), en fonction du nombre de neurones cachés (Kong A Siou, 2011-a).
La courbe en trait plein est le score sans autre régularisation que la validation croisée, la courbe en pointillé correspond au score lorsque l'arrêt précoce est utilisé ; la courbe en tireté correspond au score lorsque la modération des poids est utilisée ($\gamma = 0.01$).

III.7. Apprentissage par renforcement

a. Fonction objectif

Jusqu'à présent nous avons envisagé l'apprentissage au moyen de la minimisation d'une fonction de coût représentant l'erreur entre la sortie du modèle et une sortie désirée qui est, soit la grandeur mesurée sur un processus que le modèle doit identifier, soit la consigne imposée à un processus asservi. L'apprentissage par renforcement, proposé par A. G. Barto (Barto *et al*, 1995) revisite cette fonction de coût afin de la rendre opérante même lorsque l'on ne dispose pas des grandeurs désirées. Cette méthode s'applique pour réaliser des objectifs de haut niveau tels, pour un robot mobile autonome, la coordination des mouvements ou l'évitement d'obstacle. Le schéma général proposé par A. G. Barto, et représenté en Figure 14, comporte un *agent* effectuant des actions, et une heuristique appelée le *critique*. Le critique, proposé par B. Widrow (Widrow *et al*, 1973) analyse l'effet des actions de l'agent et envoie à cet agent un signal de renforcement, sous forme de pénalité ou de récompense, qui permet à ce dernier de s'adapter afin de satisfaire l'objectif. Par rapport à un superviseur qui connaît la valeur mesurée sur le processus à identifier, le critique donne une indication qualitative. En sus de l'introduction du critique, A. G. Barto introduit dans l'agent un processus stochastique qui lui permet, au début de l'apprentissage, de parcourir l'espace des états de manière aléatoire. Au fur et à mesure de ce parcours, le signal de renforcement permet à l'agent de modifier ses actions et ainsi de les adapter à l'objectif. Qui plus est, après avoir atteint un état stable, si une modification survient soit sur l'agent, soit dans l'environnement, une nouvelle exploration de

l'espace des états est toujours possible. Grâce à ce processus stochastique, l'agent a donc un comportement adaptatif.

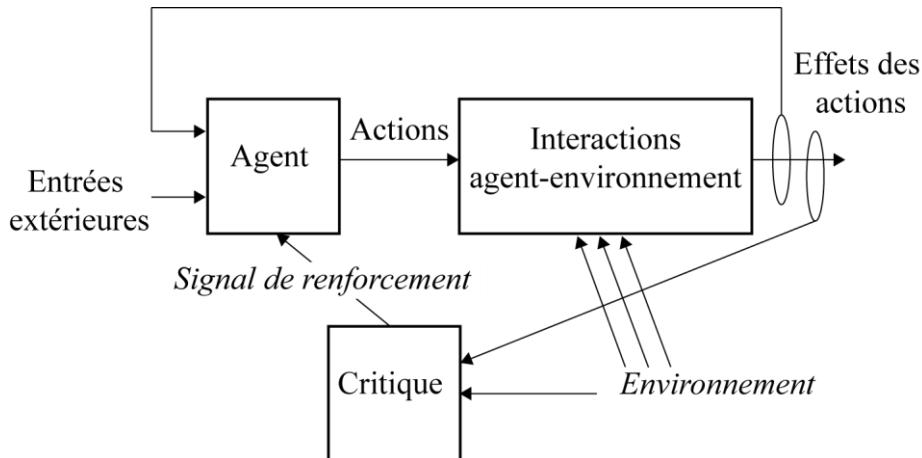


Figure 14 : Schéma de principe de l'apprentissage par renforcement

L'apprentissage par renforcement est donc intéressant pour réaliser des systèmes capables d'effectuer une tâche dans un environnement qui n'est que partiellement décrit et de s'adapter aux modifications de ce dernier, car seul l'effet des actions est analysé par le critique. Ces propriétés sont particulièrement pertinentes pour les environnements extérieurs et plus encore pour les environnements naturels.

b. Adaptativité en milieu non stationnaire

i. Apprentissage de comportements d'un robot hexapode

Lorsque j'ai intégré l'Ecole des Mines d'Alès en 1991 avec l'ambition de développer des recherches sur les algorithmes d'apprentissage, il a paru particulièrement intéressant de mettre à profit le potentiel de ces méthodes sur des systèmes naturels, c'est-à-dire mal connus et partiellement imprévisibles, ou en interaction avec un environnement naturel. Le champ de la robotique mobile était un terrain de jeux idéal et les travaux émergents à cette époque en relation avec la locomotion de robots (A. Frank, 1988) et l'éthologie (D. M. Wilson, 1966) nous ont stimulés. Le projet de conception et de réalisation d'un robot mobile autonome nous a paru un bon moyen de fédérer les compétences que l'on appellerait aujourd'hui mécatroniques¹¹. Sur une impulsion de C. Touzet (Touzet *et al*, 92), le choix s'est porté sur un robot hexapode, robot qui permettait de s'exercer à une certaine complexité, le nombre de pattes assurant cependant une bonne stabilité (Figure 15). Les caractéristiques techniques du robot ainsi conçu sont présentées dans (Johannet *et al*, 1999-b). Ce prototype a appris tous les comportements que nous lui imposions mais des limitations assez importantes de conception, en particulier la conception des pieds l'amenant, en fait, à marcher sur des "talons aiguilles" nous ont empêchés de tester toutes les fonctions. De ce fait, et pour éviter l'endommagement du robot au cours de

¹¹ L'équipe était composée de Michel Artigue, Pierre Couturier, Alexandre Meimouni, Isabelle Marc et Hugues Silvain. Autant leur bon accueil que leur travail enthousiaste a permis de mener ce projet à bout.

ses chutes multiples, un simulateur logiciel a également été développé afin d'effectuer les tests nécessaires à l'ajustement des algorithmes d'apprentissage.

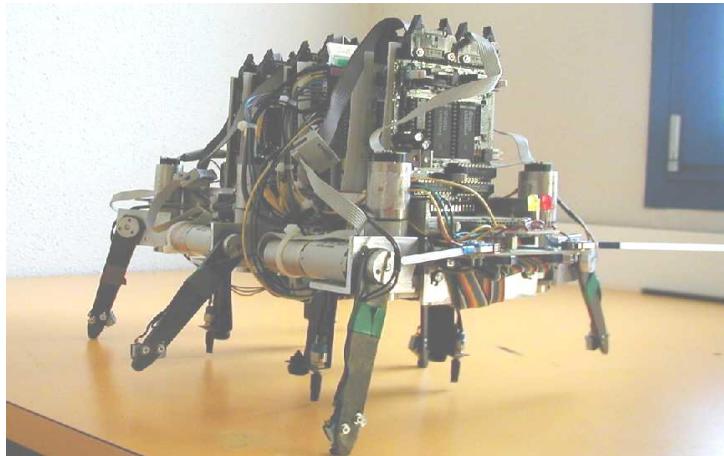


Figure 15 : Robot hexapode

Nous avons vu précédemment que l'apprentissage par renforcement, décliné comme apprentissage par pénalité et récompense, ou A_{RP}, par A. G. Barto, nécessite la définition d'un agent, d'une heuristique (le critique) et d'une règle de modification des actions. Voyons comment ces éléments ont été revisités en utilisant les réseaux de neurones.

L'agent est le contrôleur du mouvement d'une patte du robot. Le modèle le plus simple a été choisi pour préserver la parcimonie. Le mouvement de chaque patte est contrôlé par un seul neurone binaire (fonction d'évaluation de Heaviside). Ses variables sont l'état des cinq autres pattes et son propre état. Deux mouvements sont possibles : lever, avancer et poser la patte d'une part et reculer la patte d'autre part. L'exploration de l'espace des états est réalisée par un générateur de nombres aléatoires dont la valeur s'ajoute au potentiel du neurone. Le mouvement de la patte est donné par le signe du potentiel ainsi bruité.

L'apprentissage est réalisé par une règle inspirée d'une descente de gradient du premier ordre prenant en compte les signaux de pénalité et récompense, ainsi que la "*sortie non bruitée du neurone*", calculée par l'espérance mathématique de la sortie d'un neurone ayant les paramètres actuels du neurone soumis à l'apprentissage. Ainsi, l'estimation de l'incrément appliqué par l'apprentissage est déterministe (Johannet *et al*, 1999-a).

Ce type d'apprentissage a été appliqué pour l'acquisition de deux comportements : l'apprentissage de la marche et l'évitement d'obstacle. Ces deux comportements sont acquis assez rapidement après une séquence de mouvements aléatoires validant ainsi que des comportements de haut niveau peuvent être acquis au moyen de règles simples et locales. Deux types de marche sont obtenus (Figure 16), ainsi que plusieurs stratégies d'évitement d'obstacle. La capacité du robot à s'adapter à des modifications de son environnement a été validée car le robot est capable de réapprendre à marcher très efficacement s'il subit des dégradations, qui, par exemple, rendent une patte inopérante (Johannet *et al*, 1999-a). L'apprentissage par renforcement permet donc de réaliser des systèmes adaptatifs très réactifs.

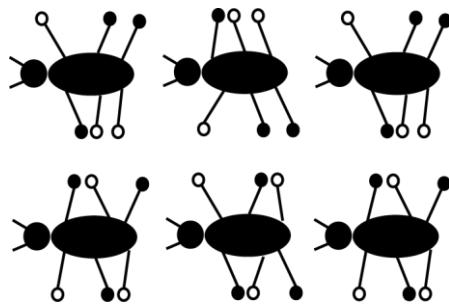


Figure 16 : Les deux types de marche hexapode découverts.

La patte figurée par un pied blanc se lève avance et se pose tandis que la patte figurée par un pied noir recule. Le type de marche du bas de la figure est une marche tripode adoptée par les insectes, la marche du haut de la figure n'est pas observée dans le monde animal.

ii. Vers l'assimilation de données en hydrologie

Dans le projet ANR FLASH (présenté ci-après section III.8.a), il est prévu d'appliquer les méthodes de l'*assimilation de données* à l'hydrologie. L'assimilation de données, qui consiste en un ensemble des méthodes statistiques permettant de prendre en compte les informations mesurées ou supposées sur le processus en cours, doit permettre d'améliorer la prévision ou l'estimation de l'état d'un système. Cette approche est à mettre en relation étroite avec les modèles statistiques obtenus par apprentissage adaptatif. On comprend qu'elle a tout son intérêt pour envisager la prévision d'événements rares et extrêmes, non encore compris dans la base d'apprentissage¹².

Si l'assimilation de données est déjà très étudiée en météorologie, et plus généralement pour la modélisation de l'atmosphère (Daley, 1993), elle est encore assez peu étudiée et utilisée en hydrologie ; quelques travaux publiés se fondent néanmoins sur l'estimation de la hauteur d'eau (Neal *et al*, 2007).

Les travaux développés actuellement sur l'assimilation de données se répartissent en deux écoles : une approche fondée sur le formalisme des filtres de Kalman, et une autre selon une approche variationnelle. Or le formalisme variationnel de l'assimilation de données est très voisin de celui de l'apprentissage statistique : dans le premier cas, il s'agit de minimiser une fonction de coût quadratique afin d'optimiser l'*ébauche* de la prévision, sous contrainte du modèle physique ; dans le second cas, il s'agit de calculer les paramètres du modèle au cours d'un apprentissage qui se déroule en même temps que l'évènement pluvieux. Les deux formalismes font appel à des optimisations quadratiques, non linéaires dans le cas de l'apprentissage statistique.

Quelques travaux ont été publiés sur l'utilisation de l'apprentissage statistique pour réaliser l'assimilation de données sur des systèmes académiques fortement non linéaires, comme le modèle proie-prédateur (Wu *et al*, 2005), ou les équations de Lorentz (Liaqat *et al*, 2003) ;

¹² L'assimilation de données a prouvé son efficacité lors de la grande tempête de 1999 qui n'avait pas son équivalent dans les archives météorologiques (Mackenzie, 2003).

néanmoins, à notre connaissance, aucun travail couplant l'apprentissage artificiel et l'assimilation de données opérant sur la chaîne hydrométéorologique n'a été publié.

Dans le cadre du projet FLASH nous pensons intéressant de comparer les deux approches permettant de conférer au modèle un caractère adaptatif ; d'une part l'apprentissage adaptatif conventionnel, que nous avons mis en œuvre pour le contrôle de la pince électropneumatique présenté en section III.4.b. et qui fait évoluer le jeu des paramètres du modèle en fonction des dernières variables mesurées par une règle de gradient dit stochastique (Widrow *et al*, 1985) ; d'autre part, l'apprentissage par renforcement qui ne nécessite que des informations qualitatives devrait avoir un grand intérêt, dans la mesure où les variables mesurées sur les systèmes hydrométéorologiques sont entachées de grandes erreurs ou incertitudes, comme nous allons le présenter dans la section suivante.

III.8. Application aux hydrosystèmes

Par hydrosystèmes nous entendons systèmes hydrologiques et systèmes hydrogéologiques. Les premiers effectuent la conversion pluie-débit puis la propagation de l'eau au sein des rivières, les seconds prennent en compte l'interaction de l'eau avec le sous-sol ainsi que son stockage. Compte-tenu de la pression anthropique exercée sur ces systèmes, leur étude est essentielle, que ce soit pour la ressource en eau ou pour le risque inondation. Les hydrosystèmes sont connus pour avoir un fonctionnement non linéaire, ne serait-ce que du fait de l'*évapotranspiration*, action d'évaporation, de consommation et de transpiration de la végétation, dont on comprend bien qu'elle est saisonnière et difficile à estimer précisément. Parmi la grande variété des hydrosystèmes, nous nous sommes intéressés à deux types d'entités emblématiques de leur complexité : les karsts et les bassins versants rapides.

a. Projets BVNE et ANR FLASH

Depuis 2006 nous travaillons en collaboration avec le Service Central d'Hydrométéorologie et d'Appui à la Prévision des Inondations, ou SCHAPI, afin d'établir un modèle de prévision des crues du Gardon d'Anduze. Le projet intitulé *Bassins Versant Numériques Expérimentaux*, ou BVNE¹³, sur lequel s'est déroulée la thèse de Mohamed Toukourou (Toukourou, 2009-b) a permis de mettre en évidence autant la grande difficulté de ce problème que les possibilités d'amélioration apportées par l'apprentissage statistique. Ces premiers résultats, très intéressants, nous ont permis de monter le projet FLASH¹⁴, soutenu par l'ANR, qui s'intéresse aux mêmes

¹³ Le projet BVNE a pour ambition de faire collaborer plusieurs équipes scientifiques autour d'un même objectif à l'aide d'une même base de données. Ce projet s'appuie sur le Service de Prévision des Crues (ou SPC) *Grand Delta*, ainsi que sur des laboratoires de recherche développant et adaptant leurs modèles hydrologiques afin d'effectuer, en temps réel, une prévision des débits à Anduze. Les équipes travaillant sur le projet sont les suivantes : Bureau de Recherches Géologiques et Minières (BRGM), CEntre national du Machinisme Agricole, du Génie Rural, des Eaux et des Forêts (CEMAGREF), Environnements DYnamiques et TERRitoires de Montagne (EDYTEM), Hydrosciences Montpellier (HSM), Institut de Mécanique des Fluides de Toulouse (IMFT), Laboratoire d'étude des Transferts en Hydrologie et Environnement (LTHE), Météo France.

¹⁴ Le projet FLASH : Flood forecasting with machine Learning, data Assimilation and Semi-pHysical modeling fait intervenir, outre l'Ecole des Mines d'Alès qui est coordonateur, trois partenaires : l'ESPCI ParisTech, par son

bassins et a pour ambition de généraliser les méthodes développées autours du bassin versant d'Anduze (Gard-France) aux autres bassins versants du Piémont Cévenol (Cèze et Ardèche), puis, afin d'y étudier les changements d'échelle tant spatiale que temporelle, d'effectuer la prévision des débits de la Somme (Somme, France). La Somme est en effet un fleuve qui est soumis à des crues de nappes de temps de réponse très long, contraint en ses limites par les fluctuations des marées qui peuvent être très importantes dans la baie de Somme. En 2001 l'inondation de la Somme a marqué l'actualité par son étendue (plus d'un millier de maisons inondées), et sa durée (deux à trois mois).

A l'opposé de la Somme, les bassins versant rapides sont des bassins versants de montagne soumis à des événements pluvieux très intenses donnant lieu à des crues aussi soudaines que dévastatrices. En septembre 2002, la petite ville d'Anduze (Gard, France) a vu se déverser sur elle, en moins de 24h, l'équivalent d'une année de précipitations en région parisienne¹⁵. En conséquence, le débit du Gardon d'Anduze est passé de 200 m³/s à plus de 2500 m³/s en quelques heures. Sur le département du Gard, cet événement pluvieux a tué près de 25 personnes et a causé plus d'un milliard d'euros de dégâts (Le Lay *et al*, 2007).

L'application des modèles hydrologiques MARINE (Bessiere *et al*, 2007) et TOPMODEL (Saulnier *et al*, 2009) à la prévision des crues du Gardon d'Anduze, met en évidence que l'application d'un champ spatialisé de précipitation est nécessaire pour obtenir de bonnes simulations de la crue. Ainsi, si les modèles hydrologiques parviennent à estimer le débit en chaque point du cours d'eau, en revanche, ils souffrent de ne pas disposer de prévision des pluies, qui sont indisponibles à une si petite échelle de quelques km².

Concernant l'apprentissage statistique, si l'absence de prévision de pluie est pénalisante, il reste cependant possible de réaliser autant de modèles que l'on demande de prévisions jusqu'à l'horizon maximal de prévision. Ainsi, Mohamed Toukourou a, dans sa thèse, élaboré six modèles de prévision, en mode dirigé, afin d'estimer les hauteurs d'eau futures aux horizons de prévision ½h, puis de 1h à 5h (Toukourou *et al*, 2010), en l'absence de prévision de pluie¹⁶.

Par ailleurs les signaux mesurés sur les hydrosystèmes sont entachés d'une grande imprécision. En premier lieu les précipitations issues de mesures effectuées par les pluviomètres ont une

Laboratoire SIGMA (Signaux, Modèles, Apprentissage statistique) ; le Laboratoire EDYTEM, Laboratoire Environnements DYnamiques et TErritoires de Montagne, Unité mixte CNRS et Université de Savoie ; et le SCHAPI, Service Central d'Hydrométéorologie et d'Appui à la Prévision des Inondations, service central du Ministère en charge de l'Ecologie qui actualise les cartes de vigilance "vigicrues" (<http://www.vigicrues.ecologie.gouv.fr/>).

¹⁵ Plus précisément 648 mm d'eau ont été relevés à Anduze par le pluviomètre du Service de Prévision des Crues Grand Delta entre le 08/09 13h et le 09/09 8h30 (TU).

¹⁶ On pourra noter que le modèle de prévision effectué par apprentissage statistique à un horizon de prévision donné h_p , n'effectue pas une prévision en supposant la pluie future nulle, hypothèse souvent posée par les utilisateurs des modèles hydrologiques pour réaliser des prévisions. En effet, les entrées de pluies futures ne sont pas proposées au réseau de neurones. De ce fait, si le réseau apprend à associer les précipitations passées (pluie tombée jusqu'au temps k) aux débits futurs (au temps $k+h_p$). On peut supposer qu'il effectue également en interne une prévision propre de ces précipitations.

précision quantifiée à 10% ou 20% (Marchandise *et al*, 2007), mais le réseau de pluviomètres (six sont disponibles pour le bassin versant d'Anduze de 540 km^2 environ) est insuffisant pour garantir que l'essentiel de l'orage ne passe pas entre deux de ces dispositifs. Par exemple, lors de l'événement de 2002, on a pu relever un cumul de précipitation près de trois fois plus important à Anduze qu'à Soudorgues, alors que les deux villes ne sont distantes que d'une quinzaine de kilomètres (Figure 17). La technique d'observation des précipitations par l'imagerie des ondes réfléchies des radars météorologiques permet l'obtention de cartes donnant les réflectivités à la définition du km^2 . Néanmoins, la transformation des réflectivités en pluie n'est pas encore totalement satisfaisante, d'une part à cause du relief ou de phénomènes physiques encore mal appréhendés, et d'autre part parce qu'elle est souvent réalisée avec l'aide de pluviomètres au sol, reportant ainsi sur les cartes radar l'imprécision des pluviomètres. En second lieu, les débits sont souvent estimés à partir des hauteurs d'eau au moyen d'une courbe de tarage qui est non linéaire. Cette courbe est établie au moyen de jaugeages expérimentaux qui permettent de mesurer les débits pour une hauteur particulière. Il est inutile de préciser ici qu'aucun jaugeage du Gardon lors des épisodes de crues très intenses ne peut être réalisé sans mettre en péril la sécurité des personnes. La courbe de tarage est donc contestable pour les très forts débits. Pour cette raison et grâce à la capacité de l'apprentissage statistique d'estimer aussi bien les hauteurs d'eau que les débits, nous avons donc préféré prévoir la hauteur d'eau.

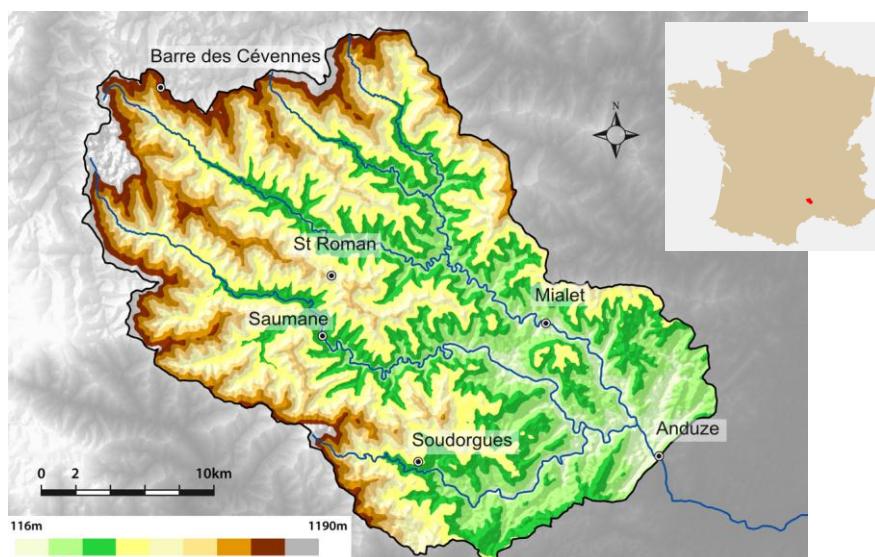


Figure 17 : Bassin versant d'Anduze (Artigue, 2010).
Le bassin versant est situé dans le Sud-Est de la France, il s'étend sur 540 km^2 environ.

Ces difficultés, ajoutées au nombre réduit d'événements de la base de données¹⁷ (17 événements disponibles, dont seulement cinq événements jugés intenses) nous ont permis de prendre la mesure du défi qui est posé aux systèmes à apprentissage statistique pour parvenir à prévoir les crues du Gardon d'Anduze. On comprend aisément que de telles imprécisions

¹⁷ Pour un hydrosystème, cette base de données est très importante ; elle est le fruit du travail régulier du SPC Grand Delta ; si nous la présentons comme "réduite" c'est en regard du nombre d'événements intenses et de la nécessité de disposer d'une base de données redondante pour l'apprentissage statistique.

soulèvent avec plus d'acuité la difficulté du surapprentissage soulevée par le dilemme biais-variance.

Face à ces difficultés, une méthodologie rigoureuse de mise en place des méthodes de régularisation précédemment exposées a été proposée et mise en œuvre par Mohamed Toukourou. La validation croisée a permis de sélectionner les meilleurs modèles au sens des critères tels que la persistance, l'erreur quadratique ou le coefficient de détermination. La validation croisée partielle, variante de la validation croisée, n'opérant que sur les événements les plus intenses afin de sélectionner les modèles les meilleurs sur ces crues, a été proposée et une comparaison entre l'arrêt précoce et la modération des poids a été menée (Toukourou *et al*, 2009-a). Dans la continuité de ce travail, Audrey Bornancin-Plantier qui effectue sa thèse dans le cadre du projet FLASH étudie exhaustivement la sélection des modèles et effectue une analyse de sensibilité sur les hyperparamètres de la règle de Levenberg-Marquardt, ainsi que sur les critères employés pour l'apprentissage et/ou la sélection des modèles (section II.b.ii).

Par ailleurs, une autre demande sociétale est émergente : celle qui concerne les bassins versants non-jaugés. Ces bassins sont ceux qui, du fait de leur taille réduite, ne disposent pas d'une station de mesure de débit (station de jaugeage), et pour lesquels on ne dispose donc pas de mesures. Bien que petits, ces bassins versant peuvent cependant recueillir des quantités de précipitation considérables, car très localisées, qui vont donc causer des dégâts et même des décès. Dans le cadre du projet BVNE nous avons entrepris, avec la thèse de Guillaume Artigue de bâtir des modèles de prévision des crues opérant sur ces bassins en s'inspirant de l'approche dite de *régionalisation*. L'approche de régionalisation consiste à effectuer un calage sur un bassin jaugé (noté A), semblable, hydrologiquement parlant, au versant cible non jaugé (noté B). Grâce à l'estimation des précipitations au moyen des cartes radar, les pluies peuvent être estimées sur le bassin B. Ainsi le modèle calé sur le bassin A peut être utilisé en prévision sur le bassin B.

Cette méthode est revisitée par Guillaume Artigue qui définit ainsi un *bassin versant normalisé régional* (le bassin A normalisé). Lors de la prévision sur un bassin B, le modèle normalisé est mis en œuvre avec les précipitations radar du bassin B, puis dénormalisé afin de délivrer les débits du bassin B à la bonne échelle. Le travail de thèse en cours concerne donc la recherche de facteurs de normalisations tant spatiaux que temporels, et la mise en œuvre de prédicteurs du type non dirigé.

b. Systèmes karstiques

Dès 1993 les karsts¹⁸, mal connus du fait de leur grande hétérogénéité spatiale, nous ont paru un champ d'application intéressant pour l'apprentissage statistique. Nos premiers travaux ont

¹⁸ Le mot karst vient d'un mot slovène qui décrit un paysage calcaire comportant des formes d'érosions particulières. Dans ce mémoire le karst est une entité géologique, formée de roches carbonatées fracturées et dissoutes en profondeur par l'eau, créant ainsi des réseaux de vides organisés. Ces réseaux sont en partie emplis d'eau, ce qui permet de qualifier les karsts de *châteaux d'eau naturels*. Les karsts contribuent à l'alimentation en eau potable pour 20 à 25% de la population (Ford *et al*, 1997).

alors porté, en collaboration avec Messieurs Alain Mangin et Dominique d'Hulst, sur le karst du Baget (Ariège-France). Ainsi, très en avance sur la communauté internationale, nous avons modélisé la relation pluie-débit du karst du Baget avec les deux prédicteurs évoqués en section III.3.a. (Johannet *et al*, 1994).

Plus récemment, alors que quelques travaux sur la thématique de l'apprentissage statistique appliqué aux karsts commencent à être publiés (Kurtulus *et al*, 2007), et bénéficiant de l'amélioration de l'apprentissage apporté par la règle de Levenberg-Marquardt, nous avons étudié le comportement du modèle non-dirigé en comparaison avec un modèle linéaire possédant les mêmes variables. Il a ainsi été mis en évidence que, en l'absence d'estimation de l'évapotranspiration potentielle, remplacée par une simple gaussienne ayant son maximum au moment des plus fortes chaleurs (quand l'évapotranspiration est supposée maximale) le modèle neuronal parvenait à une bonne modélisation (Johannet, 2010). Mettant en œuvre le prédicteur non-dirigé, il a également été possible d'alimenter le modèle par une série d'impulsions de précipitations simulées croissantes afin de visualiser la réponse à des impulsions croissantes¹⁹. Comme représenté en Figure 18, on peut noter que la réponse du modèle neuronal marque un effet de saturation pour les grandes impulsions, contrairement au modèle linéaire. Cet effet de saturation est par ailleurs explicable puisque, lors des grandes crues, le débit est contraint par la dimension des conduits à l'intérieur du karst.

Ces premières approches de modélisation hydrodynamique d'un aquifère karstique, très intéressantes, d'une part pour les interprétations physiques possibles, et d'autre part pour la demande assez faible en types de données observées (la température n'est pas mesurée mais remplacée par une gaussienne), nous ont permis d'envisager le travail de thèse de Line Kong A Siou afin d'étudier l'aquifère du karst du Lez. Ce travail a pour objectif, non seulement d'effectuer la prévision des crues, mais également de tenter d'interpréter le modèle obtenu afin d'en retirer des informations sur ce système physique où les inconnues restent nombreuses. A cette fin, nous avons appliqué la méthode dite des *boîtes transparentes*, que nous avons proposée (Johannet *et al*, 2008-a), et présentons dans le chapitre suivant.

¹⁹ On ne peut rigoureusement parler ici de réponse impulsionnelle puisque cette dernière est définie dans le cadre des systèmes linéaires, qui n'est pas le cadre de cette étude.

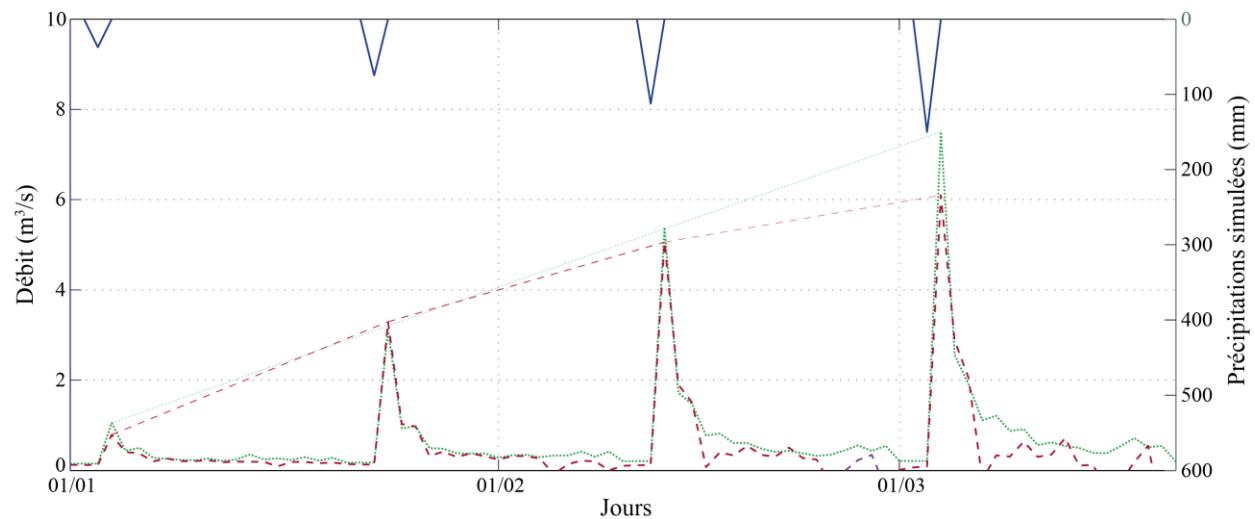


Figure 18 : Réponse du modèle à des impulsions croissantes de précipitation simulée.

En échelle négative les impulsions croissantes de pluie, en trait pointillé fin (vert) la réponse du modèle linéaire aux impulsions de pluie, en tireté (rouge) la réponse du modèle non linéaire neuronal. Les sommets des pics de crue de la réponse linéaire sont reliés entre eux par une droite afin de rendre apparente la proportionnalité des réponses du modèle linéaire, tandis que les sommets des réponses du modèle non linéaire sont reliés par des segments de droite tiretée (Johannet, 2010).

IV. Au-delà de la boîte noire

IV.1. Boîte grise et boîte transparente

a. Modélisation semi-physisque

Une autre utilisation de l'apprentissage statistique peut être de réaliser un modèle de type *boîte grise* : la part du processus qui est parfaitement connue est représentée sous la forme d'un modèle de connaissance, par exemple des équations différentielles, tandis que la part du processus qui est moins bien connue est identifiée par un modèle en boîte noire (Sjöberg *et al*, 1995). Ainsi, déclinée avec le formalisme propre des réseaux de neurones (III.3), la part modélisée de manière déterministe et la part modélisée de manière statistique peuvent être représentées avec un formalisme uniifié et l'apprentissage peut ne s'appliquer qu'à un sous-ensemble des paramètres du modèle. Y. Oussar a utilisé cette approche des boîtes grises pour modéliser le processus de séchage d'un film polymère sur un substrat (Oussar *et al*, 2001).

Si ces utilisations, qualifiées de boîte noire ou boîte grise, ont toute leur utilité, la modélisation de processus hydrométéorologiques par apprentissage statistique conduit cependant souvent à s'interroger sur la vérification de la qualité du modèle par une autre méthode que le calcul de l'erreur sur l'ensemble de validation. En effet, autant la complexité croissante des modèles et des algorithmes allant à l'encontre des principes de parcimonie préconisés dès les premières heures du développement des statistiques (Box, 1976), autant leur application à des phénomènes non stationnaires et mesurés sur une période trop courte, ne permettent pas de les évaluer de manière pleinement satisfaisante selon la seule approche statistique. Il est alors légitime, afin de le valider, de chercher à expliquer le modèle ou de chercher à retrouver les caractéristiques du processus dans les paramètres statistiques du modèle.

Pour ce faire nous avons proposé dès 1993 de contraindre l'architecture du réseau de neurones par la connaissance acquise sur le fonctionnement du processus modélisé. L'idée est de séparer les « fonctions » des « paramètres » en représentant le processus de manière modulaire et en isolant les « modules » que l'on veut étudier de façon qu'ils puissent être identifiés par un réseau de type approximateur universel. Ainsi le modèle neuronal du processus physique se compose de plusieurs perceptrons multicouches disposés en cascade.

Partant du modèle hydrodynamique du karst proposé par Alain Mangin (Mangin, 1975), qui avait l'avantage d'être déjà décomposé en différents modules, nous avons simulé le fonctionnement du karst du Baget par un ensemble de cinq sous-réseaux connectés les uns aux autres. Il s'agissait des sous-réseaux : *infiltration rapide*, *infiltration retardée*, *drain*, *systèmes annexes* et *évapotranspiration* (Johannet *et al*, 1994), (Figure 22).

Une fois l'apprentissage réalisé, on peut observer les signaux issus des sorties des sous-réseaux et ainsi, si le processus physique est correctement identifié, avoir une visualisation des évolutions des grandeurs physiques non mesurables : on peut observer le système comme si ce dernier était *transparent*. Bien évidemment, la validation des signaux ainsi obtenus empiriquement est une difficulté à ne pas négliger, elle peut être faite par des experts qui

évaluent le caractère vraisemblable de ces résultats (Johannet *et al*, 2007), ou par l'intermédiaire d'un modèle supplémentaire, d'inspiration physique, comme nous l'avons proposé dans le cadre de la thèse de Line Kong A Siou (Kong A Siou *et al*, 2010).

b. Estimation empirique de grandeurs physiques

i. Estimation de l'évapotranspiration

L'approche des boîtes transparentes a été utilisée pour estimer le signal d'évapotranspiration. Cette information est en effet cruciale pour les modèles hydrologiques qui opèrent souvent sur les pluies efficaces²⁰. Si plusieurs modèles d'évapotranspiration existent, il a également été montré par L. Oudin que la précision du modèle d'évapotranspiration n'a que peu d'importance et qu'un modèle assez rustique ne prenant en compte que l'évolution de la température pour estimer l'évapotranspiration potentielle peut suffire (Oudin *et al*, 2004).

Le modèle hypothèse de processus physique que nous avons utilisé pour simuler l'évapotranspiration est le suivant : un premier processus effectue la conversion pluie-débit, tandis que le processus d'évapotranspiration prélève de l'eau à la conversion pluie-débit (Figure 19). 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) représente les variations schématiques des variables climatiques prépondérantes sur l'évapotranspiration (température, radiations solaires).

Appliquées aux données du karst du Baget (Ariège) et après plusieurs raffinements successifs, nous avons obtenu pour l'évapotranspiration observée dans le réseau de neurones (Figure 19) une courbe différente de la gaussienne appliquée en variable d'entrée. On peut y noter en particulier une translation systématique du maximum au mois de septembre (Johannet *et al*, 2008-a). L'interprétation de ce maximum n'est pas très aisée à faire. En effet, la sortie du neurone "évapotranspiration" est le résultat d'un calcul effectué sur des variables d'entrée qui ne dépendent pas de la pluie, on penserait donc observer l'évapotranspiration potentielle. Or, il faut se souvenir que le calcul des paramètres a été effectué à partir d'une erreur calculée en sortie, qui dépend donc des précipitations observées, et ferait alors intervenir l'évapotranspiration réelle. Ce que l'on obtient à la sortie du neurone "évapotranspiration" est donc une grandeur différente des deux précédentes, qui transcrit l'eau que la végétation consomme, que cette eau vienne d'être précipitée (le Baget se situe dans les Pyrénées et est donc bien arrosé), 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.

Après avoir validé cette analyse sur d'autres bassins versants, nous pensons pouvoir utiliser ce type d'information pour évaluer l'impact d'un changement de pratiques agricoles ou d'un changement climatique sur les réserves en eau.

²⁰ 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).

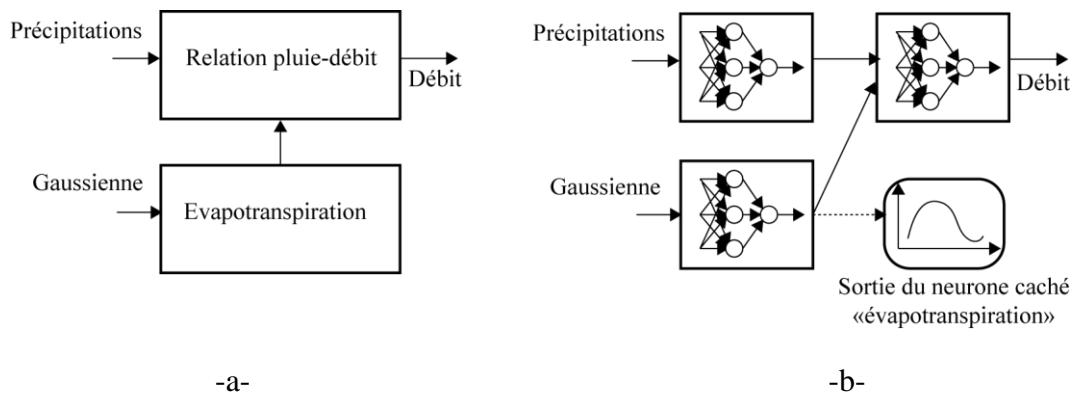


Figure 19 : Boîte transparente pour mettre en évidence l'évapotranspiration
17-a. Hypothèse physique. 17-b. Déclinaison de l'hypothèse physique en utilisant un réseau de type perceptron multicouche pour identifier chacune des fonctions physiques inconnues.

ii. Estimation de transferts d'eau souterrains

Nous avons déjà évoqué le travail de thèse de Line Kong A Siou sur l'aquifère karstique du Lez. Le cœur de son travail est l'utilisation des boîtes transparentes pour mieux connaître le fonctionnement de l'aquifère du Lez, source d'eau douce qui alimente la ville de Montpellier (agglomération de 300 000 habitants) en eau potable.

Ce travail est effectué en collaboration avec Monsieur Séverin Pistre et Madame Valérie Borrel, du Laboratoire HydroSciences Montpellier. L'aquifère du Lez est un aquifère extrêmement étudié depuis plus de 50 années du fait de son exploitation industrielle, et de nombreux modèles ont été proposés pour décrire son fonctionnement (Fleury, 2008). En quelques mots, les difficultés de l'étude de cet aquifère sont dues au fait qu'il est très hétérogène au niveau géologique et comporte des failles majeures ; il est également alimenté par des précipitations de type cévenol, très hétérogènes sur une courte échelle de temps (horaire). Du fait de son exploitation industrielle, les débits à la source sont artificialisés et les dynamiques de la vidange et du remplissage du karst sont vraisemblablement perturbées ; à cause du pompage la source est asséchée durant les mois d'été, les chroniques de débits ne sont donc plus disponibles et de plus la source du Lez n'est qu'un des exutoires de l'aquifère plus profond ; d'autres sources non pérennes existent dont le débit n'est pas mesuré (source du Lirou, des Fleurettes, ...). Enfin, les délimitations du bassin d'alimentation souterrain ne sont pas très bien connues et sont variables en fonction du niveau de remplissage du réservoir : en effet, l'aquifère se fragmente en plusieurs compartiments indépendants durant la période sèche qui sont ainsi isolés les uns des autres. Une délimitation du bassin d'alimentation a cependant été proposée par Y. Conroux (Conroux, 2007), représentée sur la Figure 20. Le bassin ainsi délimité s'étend sur environ 400 km².

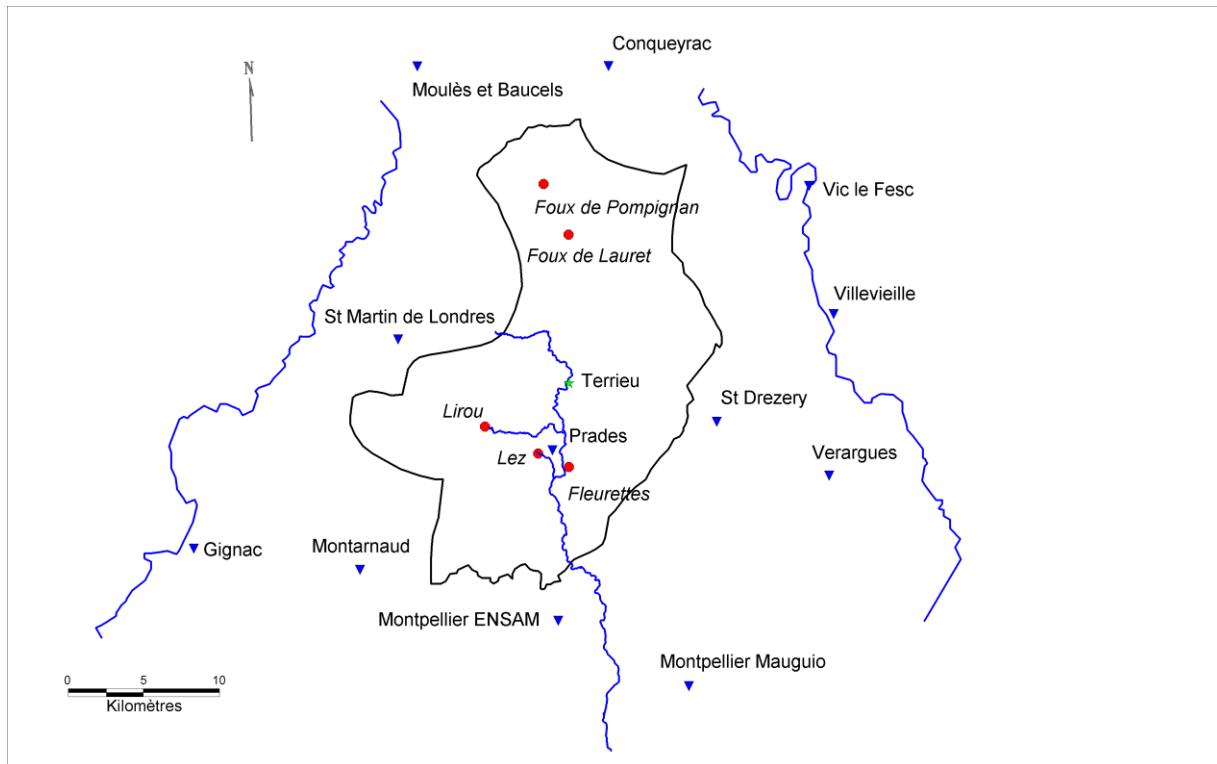


Figure 20 : Bassin d'alimentation supposé du Lez

Au centre, le Lez, à droite le Vidourle et à gauche l'Hérault. On note sur la figure : les pluviomètres utilisés (triangles), les sources connectées à l'aquifère (disques rouges) et le site de piézométrie du Terrieu (disque vert).

Afin de mieux connaître les écoulements souterrains, un découpage du bassin d'alimentation supposé en quatre zones géologiques estimées homogènes a été proposé par Kévin Cros lors de son stage de Master II effectué au Laboratoire de l'Ecole des Mines d'Alès (Cros, 2010). Relativement à chacune des zones baptisées Nord-Est, Nord-Ouest, Sud-Est et Sud-Ouest, Kévin Cros a défini autant de chroniques pour des pluviomètres virtuels qui enregistreraient les précipitations tombant sur ces zones. 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.

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 contrignant l'architecture du réseau de neurones par ces hypothèses, la boîte transparente la plus complète a été proposée telle que représentée à la Figure 21. Sa mise en œuvre a été simplifiée par souci de parcimonie et les réseaux de type identificateur universel correspondant à l'infiltration de chacune des zones ont été remplacés par un seul neurone linéaire. De l'information a été extraite de chacun de ces sous-réseaux en utilisant la méthode de sélection de variables proposée par (Yacoub, 2001) qui permet de quantifier l'importance de chacune des variables. Ainsi, Line Kong A Siou a 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'énergie²¹ issue des précipitations tombant sur la zone. Ces résultats ont été soumis pour une publication.

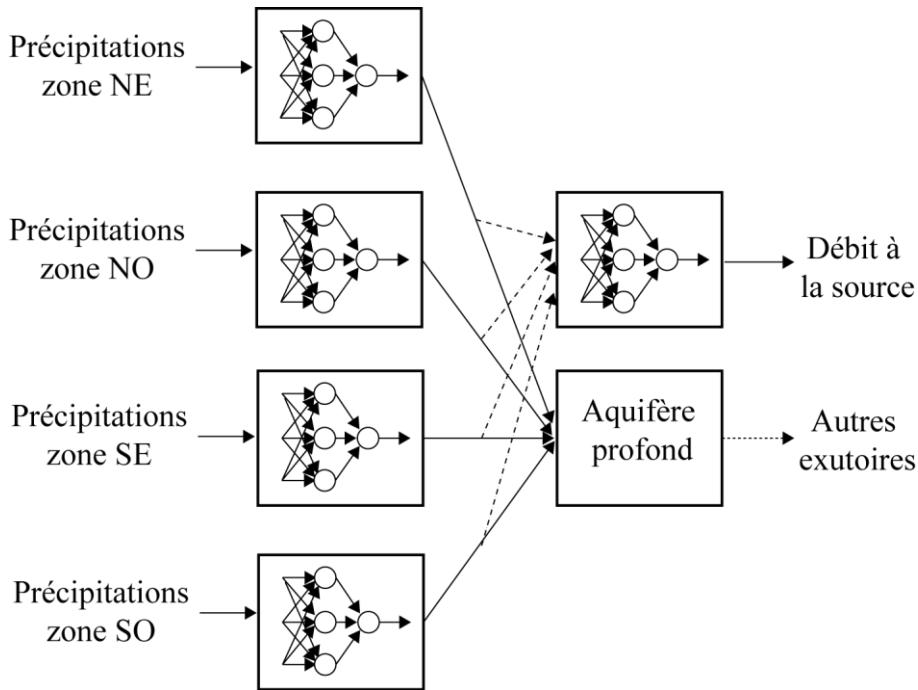


Figure 21 : Boîte transparente pour la simulation hydrodynamique de l'aquifère du Lez.

La validation de la méthode 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 la constante de temps ont été imposés et devraient donc être retrouvés dans la boîte transparente. Les résultats obtenus concernant les contributions sont synthétisés dans le Tableau 1. Il s'agit d'une moyenne sur quatre modèles du bassin virtuel, différents par leur dynamique.

²¹ Le retard estimé correspond au temps de 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. Le transfert de la matière obtenu à partir de traçages peut être rapide en crue et très lent à l'étiage.

Contribution au débit	Z1	Z2	Z3	Z4
Imposée dans le bassin-versant virtuel	33.9%	37%	8.4%	19.2%
Boîte transparente (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 1 : Validation de la méthode à partir d'un aquifère virtuel.

Appliquée au bassin d'alimentation du Lez, la méthode fournit les pourcentages de contribution de chaque zone au débit observé à la source (Tableau 2). Les contributions sont estimées à partir des paramètres médians correspondant à 50 réseaux obtenus à partir d'initialisations différentes des paramètres.

Contribution au débit	Zone NO	Zone NE	Zone SO	Zone SE
Boîte transparente	28%	44%	11%	5%
Temps de réponse (jour)	1 à 3	1	1	0

Tableau 2 : Contribution des zones estimée par la boîte transparente

Les contributions des zones au débit de la source appellent plusieurs commentaires. A la première lecture, on est surpris de la faible importance de la zone Sud-Ouest qui est pourtant une zone de recharge importante de l'aquifère ; cependant cette faible contribution est explicable car la source du Lirou draine cette zone mais cette dernière n'est jaugée que depuis moins d'un an. 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 Lez²². 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 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

²² Des piézomètres implantés sur le site du Terrieu situé à quelques kilomètres de la source (Figure 20) voient le niveau de la nappe baisser très rapidement lorsque le pompage dans le Lez est effectif (Jazayeri Noushabadi, 2009).

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 boîte transparente 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.

iii. Vers la connaissance des volumes d'eau stockés dans les karsts

Dès 1975 Monsieur Alain Mangin proposait 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 des processus élémentaires. Sa modélisation conceptuelle, fondée sur un enchaînement de blocs en cascade effectuant des opérations physiquement interprétables, représentée de manière simplifiée en Figure 22, est celle qui nous a inspiré l'idée des boîtes transparentes en 1993. Après toutes ces années et maintenant mieux armés, tant au niveau outils que méthodologie, nous pensons pouvoir reprendre ce travail pour arriver à mieux connaître le karst.

En identifiant chaque boîte proposée par Alain Mangin avec un perceptron multicouche et en « cascasant » les réseaux ainsi constitués comme représenté schématiquement à la Figure 22, nous pensons pouvoir estimer les niveaux d'eau souterrains²³, soit globalement pour l'aquifère, soit pour chacune des zones géologiques.

Sur la partie droite de la Figure 22 représentant la boîte transparente, qui correspond au modèle systémique de gauche, on note $\mathbf{p}(k)$ le vecteur des précipitations au temps discret k et à des valeurs précédentes. Compte tenu de l'évapotranspiration, la sortie de ce réseau délivre une estimation des pluies efficaces \mathbf{p}_{eff} qui sont appliquées, pour leurs valeurs récentes $\mathbf{p}_{\text{eff}}(k)$ à la fonction infiltration rapide, et pour leurs valeurs passées $\mathbf{p}_{\text{eff}}(k-r)$ à la fonction infiltration retardée. Les sorties de chacune des fonctions infiltrations ($\mathbf{i}_r(k)$ et $\mathbf{i}_l(k)$, respectivement infiltration rapide et infiltration lente) sont appliquées aux deux modules : drain et systèmes annexes qui délivrent les sorties $\mathbf{s}(k+1)$ pour les systèmes annexes et $\mathbf{y}(k+1)$ pour le drain. La connaissance du niveau de remplissage se fait en observant la sortie $\mathbf{s}(k+1)$.

Cette dernière information est très précieuse pour deux raisons. D'une part elle permet d'évaluer le niveau des réserves d'eau et est donc très utile pour un gestionnaire ; d'autre part elle permet d'estimer le remplissage du barrage écrêteur de crue que peut représenter le karst. Ainsi, en début d'automne, elle peut servir à mieux appréhender l'importance d'une éventuelle crue.

²³ Il est très difficile de pouvoir estimer le volume d'eau stocké dans un karst du fait de l'hétérogénéité de la structure. Les forages ne fournissent pas nécessairement une information généralisable puisqu'ils peuvent être réalisés dans un conduit large rempli d'eau ou dans un réseau de fines fissures très peu drainantes. Compte-tenu de la charge hydraulique, les niveaux d'eau dans ces deux types de vides ont des valeurs très différentes.

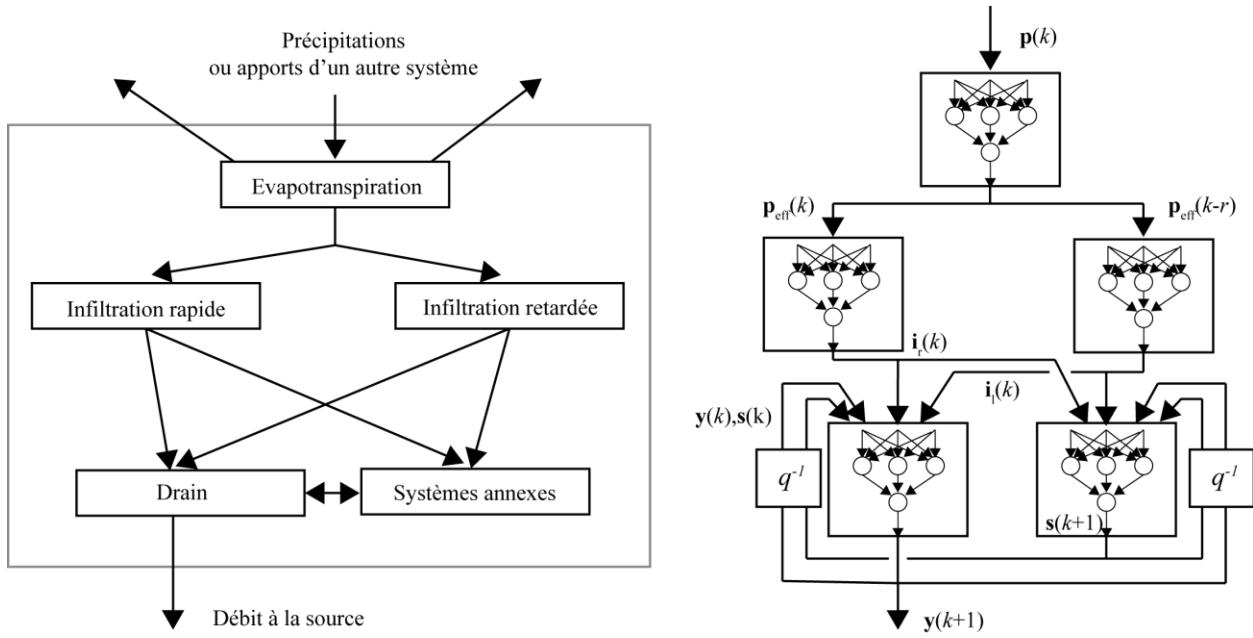


Figure 22 : Modèle systémique du karst et sa boîte transparente.

Tous les modèles sont faux ; certains sont utiles.

(G. E. Box, 1979)

V. Conclusion

Ce mémoire d'habilitation à diriger les recherches a l'ambition de présenter de manière synthétique les recherches que j'ai effectuées sur la modélisation par apprentissage statistique de systèmes naturels ou en interaction avec un environnement naturel. Au fil de mes travaux, j'ai acquis la conviction que les capacités d'apprentissage et d'identification universelle avaient un champ d'application très vaste dans la modélisation des systèmes naturels par essence non linéaires et partiellement connus.

Parmi ces derniers, les hydrosystèmes m'ont paru emblématiques des défis que la science doit permettre d'aborder. De fait, l'importance des enjeux soulevés par la ressource en eau ou la prévision des crues a déterminé l'instrumentation et le suivi de ces systèmes depuis des décennies, aboutissant ainsi à la constitution de bases de données d'une importance et d'une richesse considérables. Les scientifiques qui se sont attachés à relever ces mesures, à les consigner, les valider et les sauvegarder dans des fichiers numériques maintenant utilisables, sont évidemment les premiers que nous devons remercier. Leur travail est immense en regard de celui du modélisateur.

Comme nous l'avons soulevé dans la première partie de ce mémoire, l'apprentissage statistique, issu de l'optimisation d'une fonction de coût décomposable en fonctions paramétrées non linéaires, s'est enrichi de l'idée du compromis entre le biais et la variance, compromis qui doit être pris en compte pour déterminer la complexité adéquate du modèle. Ainsi, diminuer la variance a donné lieu à plusieurs méthodes de régularisation que nous avons présentées et que nous utilisons et revisitons pour optimiser des modèles statistiques capables d'opérer en présence de données très bruitées ou en partie incertaines.

En deuxième partie de ce mémoire nous avons présenté comment les réseaux de neurones se sont dotés d'outils performants. Autant les règles d'apprentissage modernes qu'une habile synthèse entre la théorie des systèmes et l'apprentissage statistique permettent désormais de proposer des prédicteurs adaptés aux modèles hypothèses choisis du processus que l'on identifie. Des illustrations, auxquelles nous avons contribué, ont été proposées concernant l'apprentissage de comportements d'un robot hexapode, la synthèse de régulateurs pour le contrôle en position et en pression d'une pince électropneumatique, ou la définition d'un modèle de prévision des crues rapides du bassin versant d'Anduze.

Cependant, même si nous disposons de bases de données établies sur une durée qui paraît longue, celle-ci est fort courte devant l'histoire des phénomènes hydrométéorologiques. Aussi la recherche d'un modèle capable d'adopter une bonne réponse devant des phénomènes rares ou extrêmes doit être spécifiquement menée. Face à ce questionnement, nous avons tenté de

valider le fonctionnement du modèle statistique par une autre approche que la seule mesure statistique de l'erreur de validation.

Ceci nous a conduits à proposer les boîtes transparentes, présentées en dernière partie, qui sont utiles autant pour permettre la validation par un expert que pour retirer des enseignements sur le système étudié. Trois illustrations de cette démarche originale ont été proposées, depuis l'estimation des flux d'eau souterrain, à celle de l'évapotranspiration pour déboucher sur la proposition de l'estimation du remplissage en eau d'un aquifère karstique.

Si j'ai bien conscience que la complexité des systèmes et des algorithmes utilisés dans l'approche des réseaux de neurones peut donner le vertige autant à un naturaliste qu'à un statisticien des premières heures qui effectuait les calculs à la main et prônait déjà la parcimonie, je n'en reste pas moins convaincue que les pistes que j'ai pu esquisser dans ce mémoire vont nous permettre, en collaboration étroite avec les spécialistes des sciences naturelles et des sciences physiques, de mettre en œuvre des méthodes fiables permettant de mieux identifier et mieux connaître ces processus physiques pour l'instant si mal connus et pourtant tellement importants.

VI. Références bibliographiques

- F.L. Alt. *Archaeology of computers: Reminiscences, 1945—1947*. In Communications of the ACM, special issue: Twenty-fifth anniversary of the Association for Computing Machinery, vol. 15 **7**, pp. 693-694 (1972).
- G. Artigue. *Prévision des crues éclair par réseaux de neurones : généralisation aux bassins non jaugés*. Rapport d'avancement de première année de thèse, 63 p. (2010).
- A.G. Barto. *Reinforcement learning*. In The Handbook of Brain Theory and Neural Networks, pp. 804-809 (1995).
- A. R. Barron. *Universal Approximation Bounds for Superpositions of a Sigmoidal Function*. In IEEE Transactions on Information Theory, vol. 39, pp. 930-945 (1993).
- E. Bender. *Mathematical Methods in Artificial Intelligence*. IEEE Computer Society Press, 636 p. (1996).
- H. Bessiere, H. Roux, D. Dartus. *Data assimilation and distributed flash flood modeling*. In: Second Space for Hydrology Workshop, Surface Water Storage and Runoff: Modeling, In-situ data and Remote Sensing, pp. 12-14 (2007).
- C. M. Bishop. *Neural Networks for Pattern Recognition*. Oxford University Press, 482 p. (1995).
- G. J. Bowden, G. C. Dandy, Holger R. Maier. *Data Transformation for Neural Network Models in Water Resources Applications*. In Journal of Hydroinformatics, vol. 5, pp. 245-258 (2003).
- G. E. P. Box. Science and Statistics. In Journal of the American Statistical Association. Vol. 71 **356**, pp. 791-799 (1976).
- G. E. P. Box. *Robustness in the strategy of scientific model building*. In Robustness in Statistics, R.L. Launer, G.N. Wilkinson, ed. (1979).
- Y. Conroux. *Caractérisation du fonctionnement hydrodynamique de l'aquifère karstique du Lez (Hérault) à l'état naturel*. Master II de l'Université d'Avignon (2007).
- P. Couturier. *Commande par réseaux de neurones : application au contrôle d'un préhenseur électropneumatique*. Thèse de doctorat de l'INSA de Lyon en spécialité : Automatique Industrielle. (1997).
- P. Couturier, A. Johannet, M. Bétemps. *Neural Controllers: Tracking and Regulation of a Nonlinear Pneumatic Plant*. In International Journal of Knowledge-Based intelligent Engineering Systems, vol. 2 **4**, pp. 233-246 (1998).
- K. Cros. *Prise en compte du karst dans la modélisation par réseaux de neurones appliquée au Lez*. Université Pierre et Marie Curie. Master 2 Sciences de l'Univers, Environnement, Ecologie, Parcours Hydrologie-Hydrogéologie, (2010).
- T. Cybas, F. Folgeman-Soulié, P. Gallinari, S. Raudys. *Variable Selection with Neural Networks*. In Neurocomputing, vol. 12, pp. 223-248 (1996).

- R. Daley. *Atmospheric data analysis*. Cambridge University Press, 457 p. (1993).
- G. Dreyfus, M. Samuelides, J.-M. Martinez, M.-B. Gordon, F. Badran, S. Thiria, L. Hérault. *Apprentissage statistique*. Eyrolles 450 p. (2008).
- J. L. Elmann. *Finding structure in time*. In Cognitive Science, vol. 14, pp. 179–211 (1990).
- P. Fleury, B. Ladouche, Y. Conroux, H. Jourde, N. Dörfliiger. *Modelling the hydrologic functions of a karst aquifer under active water management - The Lez spring*. In Journal of Hydrology, 365 3-4, pp. 235-243 (2008).
- A. Frank. *Walkers*. In Encyclopaedia of Robotics: Application and Automation, DGRF, ed. Wiley Interscience (1988).
- D. Ford, P. Williams. *Karst Hydrogeology and geomorphology*. 562 pp., John Wiley and Sons ed. (2007).
- P. Gallinari, T. Cibas. *Practical complexity control in multilayer perceptrons*. In Signal Processing, vol. 74, pp. 29-46 (1999).
- S. Geman, E. Bienenstock, R. Doursat. *Neural Networks and the Bias / Variance Dilemma*. In Neural Computation, vol. 4, pp. 1-58 (1992).
- H. Gomi, M. Kawato. *Neural Network Control for a Closed-Loop System Using Feedback-Error-Learning*. In Neural Networks, vol. 6 pp. 933-946 (1993).
- HEC-HMS. <http://www.hec.usace.army.mil/software/hec-hms/>
- K. Hornik, M. Stinchcombe, H. White. *Multilayer Feedforward Networks are Universal Approximators*. In Neural Networks, vol. 2, pp. 359-366 (1989).
- M. R. Jazayeri Noushabadi. *Characterisation of relationships between fracture network and flow-path Network in fractured and karstic reservoirs. Numerical modeling and field investigation (Lez aquifer, Southern France)*. Thèse de l'Université Montpellier II (2009).
- A. Johannet, I. Sarda. *Goal-Directed Behaviours by Reinforcement Learning*. In Neurocomputing, vol. 28, pp. 107-125 (1999-a).
- A. Johannet, I. Sarda. *Reinforcement Learning of a Six Legged Robot to Walk and Avoid Obstacles*. In Soft Computing for intelligent Robotic Systems. L.C. Jain, T. Fukuda, eds (Springer-Verlag, 1999-b).
- A. Johannet, P.A. Ayral, B. Vayssade. *Modelling non Measurable Processes by Neural Networks: Forecasting Underground Flow. Case Study of the Cèze Basin (Gard-France)*. In Advances and Innovation in Systems, Computing Sciences and Software Engineering, Springer, pp. 53-58 (2007).
- A. Johannet, B. Vayssade, D. Bertin. *Neural Networks: From Black Box Towards Transparent Box. Application to Evapotranspiration Modeling*. In International Journal of Computational Intelligence, vol. 4 3 pp. 163-170 (2008-a).
- A. Johannet, A. Mangin, B. Vayssade. *Modélisation d'un système karstique par réseaux de neurones. Simulation des débits du karst du Baget-France*. In Cahiers de Géographie-collection EDYTEM vol. 7, pp. 51-62 (2008-b).

- A. Johannet. *Artificial Neural Networks*. In Environmental hydraulics 2: Mathematical Models, J.M. Tanguy, ed. (2010).
- M. I. Jordan, D. E. Rumelhart. *Forward Models: Supervised Learning with a distal Teacher*. In Cognitive Science, vol.16, pp. 307-354 (1992).
- P. K. Kitadinis, R. Bras. *Real-Time forecasting with a conceptual hydrologic model, applications and results*, In Water Resources Research, vol 16 **6**, pp. 1034-1044 (1980).
- L. Kong A Siou, A. Johannet, V. Borrell, S. Pistre. *Prise en compte de l'hétérogénéité géologique dans la modélisation pluie-débit par réseaux de neurones. Cas du karst du Lez*. Communication aux Journées de l'Association Française de Karstologie, Habkern (2010).
- L. Kong A Siou, A. Johannet, V. Borrell, S. Pistre. *Optimization of the generalization capability for rainfall-runoff modeling by neural networks: The case of the Lez aquifer (southern France)*; article sélectionné pour un numéro spécial de Journal of Environmental Earth Sciences (2011-a).
- L. Kong A Siou, A. Johannet, V. Borrell, S. Pistre. *Complexity selection of a neural network model for karst flood forecasting: The case of the Lez Basin (southern France)*. In Journal of Hydrology, 403 **3-4**, pp.367-380 (2011-b).
- B. Kurtulus, M. Razack. *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, vol. 15 **2**, 241–254 (2007).
- M. Le Lay, G. M. Saulnier. *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, vol. 34, L13401 5 p. (2007).
- A. Liaqat, M. Fukuhara, T. Takeda. *Optimal estimation of parameters of dynamical systems by neural network collocation method*. Computer Physics Communications, Vol. 150 **3**, pp. 215-234 (2003).
- D. Mackenzie. *Ensemble Kalman filters bring weather models up to date*. In SIAM News 36(8). <http://www.siam.org/siamnews/10-03/toc03.htm> (2003).
- A. Mangin. *Contribution à l'étude hydrodynamique des aquifères karstiques*. Laboratoire souterrain du Centre national de la recherche scientifique. Thèse de l'Université de Dijon (1975).
- A. Marchandise. *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 les processus hydrologiques*. Université Montpellier II, 184 p.(2007).
- R. Moussa. *When monstrosity can be beautiful while normality can be ugly: assessing the performance of event-based flood models*. Hydrol. Sci. J., vol. 55 **6**, pp. 1074-1084 (2010).
- J. E. Nash, J. V. Sutcliffe. *River Flow Forecasting through Conceptual Models. Part I – A Discussion of Principles*, In Journal of Hydrology, vol. 10, pp. 282-290 (1970).
- J. C. Neal, P. M. Atkinson, C. W. Hutton. *Flood inundation model updating using a ensemble Kalman filter and spatially distributed measurments*. Journal of Hydrology, vol. 336, pp. 401-415 (2007).

- O. Nerrand, P. Roussel-Ragot, L. Personnaz, G. Dreyfus, S. Marcos. *Neural networks and non-linear adaptive filtering : unifying concepts and new algorithms*. Neural Computation, vol. 5, pp. 165-197 (1993).
- L. Oudin. *Recherche d'un modèle d'évaporation potentielle pertinent comme entrée d'un modèle pluie-débit global*. Thèse de doctorat, ENGREF, Paris, 290 pp (2004).
- Y. Oussar, G. Dreyfus. *How to Be a Gray Box: Dynamic Semi-Physical Modeling*. In Neural Networks, vol 14 **9**, pp. 1161-1172 (2001)
- C. Perrin. *Vers une amélioration d'un modèle global pluie-débit au travers d'une approche comparative*. Thèse de Doctorat, INPG (Grenoble) / Cemagref (Antony), 530 p. (2000).
- W. H. Press, S. A. Teukolsky, W. T. Vetterling, B. P. Flannery. *Numerical Recipies in C*, Cambridge University Press (1992).
- G.-M. Saulnier, M. Le Lay. Sensitivity of flash flood simulations on the volume, the intensity and the localization of rainfall in the Cévennes- Vivarais region (France). In Water Resources Research, vol. 45, W10425 (2009).
- J. Sjöberg, Q. Zhang, L. Ljung, A. Benveniste, B. Delyon, P Y. Glorennec, H. Hjalmarsson, A. Judiský. *Nonlinear black-box modeling in system identification: a unified overview*. In Automatica, vol. 31, pp. 1691-1724 (1995).
- M. Stone. *Cross-validatory choice and assessment of statistical predictions*. In Journal of the Royal Statistical Society, B36, pp. 111-147 (1974).
- H. Stoppiglia, G. Dreyfus, R. Dubois, Y. Oussar. *Ranking a random feature for variable and feature selection*. In Journal of Machine Learning Research, vol. 3, pp. 1399-1414 (2003).
- K. P. Sudheer, P. C. Nayak, K. S. Ramasastri. *Improving Peak Flow Estimates in Artificial Neural Network River Flow Models*. In Hydrological Processes, vol. 17, pp. 677-686 (2003).
- M. Toukourou, *Modélisation de la relation pluie-hauteur d'eau*. In Rapport de fin de première année de thèse, 95 p. (2007).
- M.S. Toukourou, A. Johannet, G. Dreyfus. *Flash Flood Forecasting by Statistical Learning in the Absence of Rainfall Forecast: A Case Study*. In International Conference on Engineering Applications of Neural Networks 2009. Communications in Computer and Information Science Serie, D. Palmer-Brown *et al* eds (Springer, Londres, 2009-a).
- M. Toukourou. *Application de l'apprentissage artificiel aux prévisions des crues éclair*. Thèse de doctorat de l'Ecole des Mines de Paris en spécialité : Informatique Temps Réel, Robotique et Automatique. (2009-b).
- M. Toukourou, A. Johannet, G. Dreyfus, P.A. Ayral. *Rainfall-Runoff Modeling of Flash Floods in the Absence of Rainfall Forecasts: the Case of "Cévenol Flash Floods"*. In Applied Intelligence, in press, (online) (2010).
- C. Touzet, O. Sarzeaud, *Application d'un algorithme d'apprentissage par pénalité récompense à la génération de formes locomotrices hexapodes*. In Journées de Rochebrune, AFCET (1992).

- B. Widrow, N. K. Gupta, S. Maitra. *Punish/Reward Learning with a Critic in Adaptive Threshold Systems*, IEEE Transactions on Systems, Man, and Cybernetics, vol. 5 **3**, pp. 455-465 (1973).
- B. Widrow, S.D. Stearns. *Adaptive Signal Processing*. Prentice Hall, Englewood Cliffs, NJ, 528 p. 1985.
- D. M. Wilson, *Insect walking*. In Annual Review of Entomology, vol. 11, pp. 103-122(1966).
- J. Wu, M. Fukuhara, T. Takeda. *Parameter estimation of an ecological system by a neural network with residual minimization training*. In Ecological Modelling, vol. 189 **3-4**, pp. 289-304 (2005).
- M. Yacoub, Y. Bennani. *Une mesure de pertinence pour la sélection de variables dans les perceptrons multicouches*. In Revue d'Intelligence Artificielle, vol.15, pp. 393-410 (2001).

Annexes

Résumé des travaux de recherche

Depuis 1985, mes travaux de recherche portent sur l'apprentissage statistique. La première expérience est celle de la thèse qui s'est déroulée au Laboratoire d'Electronique de l'ESPCI sous la direction de Monsieur Gérard Dreyfus. Il s'agissait, d'une part, d'implémenter les réseaux de neurones de type Hopfield, et d'autre part, de paralléliser les calculs sur plusieurs processeurs parallèles afin d'accélérer les temps d'exécution. Ces travaux nous ont permis d'étudier l'influence de la précision du codage des paramètres du réseau sur la qualité de la mémoire ainsi réalisée [RO3].

En 1991, j'ai intégré l'école des Mines d'Alès. Après 2 périodes d'activité d'enseignement et de recherche en laboratoire (1991-1999) et (2006-2011) qui m'ont permis d'initier des recherches en apprentissage statistique dans des équipes aux compétences et activités très différentes, *le fil directeur de mes travaux peut être reformulé comme l'application des méthodes d'apprentissage artificiel, notamment des réseaux de neurones, à des systèmes complexes, mal connus, qu'ils soient naturels ou artificiels, en interaction avec un environnement naturel.* Si rajouter la complexité d'un réseau de neurones à un système cible déjà mal décrit peut paraître trop ambitieux ou voué à l'échec, j'ai toujours cru, au contraire, que les questionnements soulevés par ces systèmes cibles peuvent faire progresser, également, la connaissance sur l'apprentissage statistique.

Le premier exemple que je choisirai de présenter est celui d'un robot hexapode. Partant du principe que l'environnement naturel ne peut être décrit parfaitement, nous nous sommes inspirés, avec mes collègues de l'EMA, des travaux de A.G. Barto pour proposer l'apprentissage de comportement de ce robot par une méthode de renforcement utilisant une fonction *objectif*. Ainsi, deux comportements nécessitant coordination et anticipation (l'évitement d'obstacles et l'apprentissage de la marche) ont été évalués avec succès dans un environnement changeant (modification des obstacles, réapprentissage sur 5 pattes) [RO6]. J'ai également contribué aux travaux concernant la commande adaptative de processus non linéaire ou non stationnaire par réseaux de neurones [RO4].

Dès 1993, j'ai pris contact avec Monsieur Alain Mangin afin de travailler sur la modélisation des karsts, aquifères non-linéaires et spatialement très hétérogènes. Très en avance sur la communauté internationale, nous avons jeté les bases de la recherche que j'effectue actuellement [C10]. À partir de 2006, j'ai pu concrétiser ces travaux en étudiant la prévision des crues rapides et la modélisation des karsts. Ces deux thématiques hydrologiques ont en commun la disponibilité de bases de données observées depuis plusieurs décennies, la non-linéarité des processus impliqués dans ces phénomènes, la difficulté à mesurer les variables d'état, la présence d'un bruit de mesure considérable. Considérant le dilemme biais-variance qui est au cœur des recherches sur l'apprentissage statistique, ces signaux et systèmes nous ont conduits à revisiter les méthodes de régularisation [RO10]. Ainsi, j'ai proposé et coordonné le projet ANR FLASH, dont les partenaires sont l'ESPCI Paris-Tech, le laboratoire EDYTEM et le SCHAPI (qui alimente en temps réel la carte de vigilance crue sur internet). Ce projet permet

de prolonger les travaux précédents en s'intéressant à la modélisation systémique de l'ensemble de la chaîne hydrométéorologique sur les bassins versants du Piémont Cévenol. En complément, les enjeux forts portant sur les bassins versants trop petits pour qu'une station de mesure soit maintenue, ou bassins non jaugés, nous ont conduits à proposer un modèle de *bassin versant normalisé* virtuel. Enfin, sur le volet karst, la méthode des *boîtes transparentes* qui vise à contraindre l'architecture d'un réseau de neurones afin de pouvoir interpréter les variables internes du réseau en tant que grandeur physique a fait ses preuves tant sur l'évapotranspiration [RO7] que la modélisation hydrodynamique du bassin d'alimentation souterrain du Lez.

Ce type de démarche a également été proposé pour la caractérisation des suspensions minérales, systèmes physiques au comportement complexe, montrant ainsi la possibilité d'améliorer la connaissance sur ces processus [RO12].

Liste des publications

THÈSE

Les réseaux de neurones formels : étude d'un simulateur à architecture parallèle et conception d'un circuit intégré. Thèse de Doctorat de l'Université Paris VI (1990). Directeur de thèse : Gérard Dreyfus.

REVUES ET CHAPITRES D'OUVRAGES

- RO1. L. Personnaz, A. Johannet, G. Dreyfus. *Problems and Trends in Integrated Neural Networks*. In Connectionism in Perspective, R. Pfeifer, Z. Schreter, F. Fogelman, eds (Elsevier, 1989).
- RO2. P.Y. Alla, G. Dreyfus, J.D. Gascuel, A. Johannet, L. Personnaz, J. Roman, M. Weinfeld. *Silicon Integration of Learning Algorithms*. In VLSI Design of Neural Networks, U. Ramacher, U. Rükert, eds (K.A.P., 1991).
- RO3. A. Johannet, L. Personnaz, G. Dreyfus, J.D. Gascuel, M. Weinfeld. *Specification and Implementation of Digital Hopfield-Type Associative Memory with On-Chip Training*. In IEEE Transactions on Neural Networks, vol. 3, pp. 529-539 (1992).
- RO4. P. Couturier, A. Johannet, M. Bétemps. *Neural Controllers: Tracking and Regulation of a Nonlinear Pneumatic Plant*. In International Journal of Knowledge-Based intelligent Engineering Systems, vol. 2 4, pp. 233-246 (1998).
- RO5. A. Johannet, I. Sarda. *Reinforcement Learning of a Six Legged Robot to Walk and Avoid Obstacles*. In Soft Computing for intelligent Robotic Systems. L.C. Jain, T. Fukuda, eds (Springer-Verlag, 1999).
- RO6. A. Johannet, I. Sarda. *Goal-Directed Behaviours by Reinforcement Learning*. In Neurocomputing, vol. 28, pp. 107-125 (1999).
- RO7. A. Johannet, B. Vayssade, D. Bertin. *Neural Networks: From Black Box Towards Transparent Box. Application to Evapotranspiration Modeling*. In International Journal of Computational Intelligence, vol. 4 3 pp. 163-170 (2008).
- RO8. A. Johannet, A. Mangin, B. Vayssade. *Modélisation d'un système karstique par réseaux de neurones. Simulation des débits du karst du Baget-France*. In Cahiers de Géographie-collection EDYTEM vol. 7, pp. 51-62 (2008).
- RO9. A. Johannet. *Modèles à réseaux de neurones formels*. In De la goutte de pluie jusqu'à la mer – Traité d'hydraulique environnementale, vol. 4, J. M. Tanguy ed. (Hermes-Lavoisier, 2009).
- RO10. M. Toukourou, A. Johannet, G. Dreyfus, P.A. Ayral. *Rainfall-Runoff Modeling of Flash Floods in the Absence of Rainfall Forecasts: the Case of "Cévenol Flash Floods"*. In Applied Intelligence, in press, (online) (2010).

- RO11. A. Johannet. *Artificial Neural Networks*. In Environmental hydraulics 2: Mathematical Models, J.M. Tanguy, ed. (2010).
- RO12. J. Bongono, N. Azema, A. Johannet, P. Gaudon, *Determination of the Characteristics of Agglomerates in Aqueous Suspensions using Nonlinear Optimization*. In Powder Technology, vol. 208 **2**, pp. 271-278 (2011).
- RO13. L. Kong A Siou, A. Johannet, V. Borrell, S. Pistre. *Optimization of the generalization capability for rainfall-runoff modeling by neural networks: The case of the Lez aquifer (southern France)*; article sélectionné pour un numéro spécial de Journal of Environmental Earth Sciences (2011).
- RO14. L. Kong A Siou, A. Johannet, V. Borrell, S. Pistre. *Complexity selection of a neural network model for karst flood forecasting: The case of the Lez Basin (southern France)*. In Journal of Hydrology, 403 **3-4**, pp.367-380 (2011).

CONFÉRENCES AVEC ACTES

- C1. L. Personnaz, I. Guyon, A. Johannet, G. Dreyfus, G. Toulouse. *A Simple Selectionist Learning Rule for Neural Networks*. In Neural Network for Computing (AIP Conference Proceedings, Snowbird, 1986).
- C2. A. Johannet, G. Lohéac, L. Personnaz, I. Guyon et G. Dreyfus. *A Transputer-Based Neurocomputer*. In 7th OCCAM User's Group Meeting, T. Muntean, ed (Grenoble, 1987).
- C3. I. Guyon, A. Johannet, L. Personnaz, G. Dreyfus. *Local Learning Rules*. In Neural Network for Computing, (Snowbird, Utah, 1987).
- C4. A. Johannet, L. Personnaz, G. Dreyfus, M. Weinfeld. *A Fully Digital CMOS Integrated Hopfield Network Including the Learning Algorithm*. In Neural Network for Computing, (Snowbird, Utah, 1988).
- C5. L. Personnaz, A. Johannet, G. Dreyfus, M. Weinfeld. *Towards a Neural Network Chip: A Performance Assessment and a Simple Example*. In Neural Networks from Models to Applications, L. Personnaz, G. Dreyfus, eds (I.D.S.E.T., Paris, 1989).
- C6. G. Lebreton, A. Johannet, L. Personnaz, G. Dreyfus. *Design of an experimental opto-electronic neural network simulator*. In Neural Networks from Models to Applications, L. Personnaz, G. Dreyfus, eds (I.D.S.E.T., Paris, 1989).
- C7. G. Dreyfus, J.D. Gascuel, A. Johannet, L. Personnaz, M. Weinfeld. *A Digital CMOS Fully Connected Neural Network with in-Circuit Learning Capability and Automatic Identification of Relaxation on Spurious Attractors*. In Neural Network for Computing (Snowbird, Utah, 1991).
- C8. D. Achvar, A. Johannet, J. Magnier. *Séparation de sources : application à la détection des défauts d'un masque de circuit intégré*. In Actes de la conférence Neurosciences et Sciences de l'Ingénieur (Oléron, 1992).
- C9. D. Achvar, A. Johannet, J. Magnier. *Problème de séparation de signaux comprenant des retards - Illustrations*. In 5th International Conference on Neural Networks and their Applications Neuro-Nîmes'92 (EC2-1992).

- C10. A. Johannet, A. Mangin, D. D'Hulst. *Subterranean Water Infiltration Modelling by Neural Networks: Use of Water Source Flow*. In Proceedings of ICANN 1994, M. Marinaro, P.G. Morasso, eds (Springer-Verlag, 1994).
- C11. A. Johannet, I. Sarda. *Gait Learning of an Hexapod Robot: from Simulation to Realization*. In Proceedings of the 2nd Japan-France Congress on Mechatronics, (Takamatsu, Japan, 1994).
- C12. P. Couturier, A. Johannet, I. Sarda et C. Touzet. *Robot hexapode : réalisation et apprentissage de la marche*. In Actes de la conférence Neurosciences et Sciences de l'Ingénieur (Chamonix 1994).
- C13. I. Sarda, A. Johannet. *Behavior Learning by a Reward Penalty Algorithm: from Gait Learning to Obstacle Avoidance by Neural Networks*. In Artifical Neural Networks and Genetic Algorithms, D.W. Pearson, N.C. Steel, R.F. Albrecht, eds (Springer-Verlag, 1995).
- C14. P. Couturier, A. Johannet, M. Bétemp. *Feedforward Neural Controller Using Feedback Error Learning for a Pneumatic Actuator Control*. In Proceedings of Neur'Ap 95 (Marseille, 1995).
- C15. P. Couturier, A. Johannet, M. Bétemp. *Synthesis of a Feedback Neural Controller*. In CESA'96 IMACS Multiconference: computational engineering in systems applications (Lille, 1996).
- C16. P. Couturier, A. Johannet, M. Bétemp. *Neural Control of an Electropneumatic Actuator for a Gripper Device*. In Proceedings of the 3nd Japan-France Congress on Mechatronics (Besançon, 1996).
- C17. A. Johannet, I. Sarda, P. Couturier. *Apprentissage de comportements par un robot hexapode : de l'apprentissage de la marche à l'évitement d'obstacle*. In Actes de la conférence Neurosciences et Sciences de l'Ingénieur (Marly le Roi, 1996).
- C18. P. Couturier, A. Johannet, M. Bétemp. *Neural Networks for Optimal Control: Learning With Joint Displacement and Control Errors. Application to the Position Control of a Pneumatic Gripper Device*. In Proceedings of Neur'Ap 97 (Marseille, 1997).
- C19. P. Couturier, A. Johannet, M. Bétemp. *Synthesis of a Discrete-Time Feedback Neural Controller*. In IEEE International Conference on Neural Networks (ICNN'97) (Houston, 1997).
- C20. P. Couturier, A. Johannet, M. Bétemp. *Nonlinear Control Based on Neural Networks: Comparison between Different Schemes*. In proceedings of ICSC conference on Soft Computing (SOCO 97) (Nîmes, 1997).
- C21. A. Johannet, D. Diep, P. Bonnefoy, F. Harroy. *Neural-Based Methods for Classification: Comparison, Implementation and Application*. In proceedings of ICSC conference on Soft Computing (SOCO 97) (Nîmes, 1997).
- C22. D. Diep, A. Johannet, P. Bonnefoy, F. Harroy. *Obstacle Identification by an Ultrasound Sensor Using Neural Networks*. In International Conference on Artifical Neural Networks and Genetic Algorithms, G.D. Smith, N.C. Steele, eds (Springer, 1997).
- C23. Y. Liu, R. Bataille, P. Couturier, A. Johannet, P. Massotte. *Génération de plans d'action et aide au diagnostic par réseaux de neurones*. In Actes de la conférence Neurosciences et Sciences de l'Ingénieur (Munster, 1998).

- C24. D. Diep, A. Johannet, P. Bonnefoy, F. Harroy, P. Loiseau. *Classification of Sonar Data for a Mobile Robot using Neural Networks*. In IEEE Symposium on Intelligence and Systems, (Washington DC, 1998).
- C25. A. Johannet, I. Sarda. *Acquisition of Behaviours by Reinforcement Learning*. In Neural Networks and Their Applications NEURAP'98, (Marseille, 1998).
- C26. J.P. Veillez, C. Ghilardi, G. Saussac, A. Johannet, M. Nemoz-Gaillard. *CYBema : retour sur la mise en place d'un extranet pédagogique*. In Technologies de l'Information et de la Connaissance dans l'Enseignement Supérieur et dans l'Industrie (Compiègne, 2004).
- C27. A. Johannet, P.A. Ayral, B. Vayssade. *Modelling non Measurable Processes by Neural Networks: Forecasting Underground Flow. Case Study of the Cèze Basin (Gard-France)*. In International Joint Conferences on Computer, Information, Systems Sciences, and Engineering. Advances and Innovation in Systems, Computing Sciences and Software Engineering (Conférence virtuelle, 2007).
- C28. J.-P. Veillez, A. Johannet, L. Mignano. *IFG4 : le pilotage pédagogique au cœur de 7 sessions de formation d'ingénieur à distance par internet*. In Technologies de l'Information et de la Connaissance dans l'Enseignement Supérieur et dans l'Industrie (Compiègne, 2008).
- C29. M. Toukourou, A. Johannet, P.A. Ayral, G. Dreyfus. *Prévision des crues éclair par apprentissage artificiel : application au Gardon d'Anduze*. Conférence invitée, In 5ièmes Journées Géorisque, (Montpellier, in Press 2009).
- C30. M.S. Toukourou, A. Johannet, G. Dreyfus. *Flash Flood Forecasting by Statistical Learning in the Absence of Rainfall Forecast: A Case Study*. In International Conference on Engineering Applications of Neural Networks 2009. Communications in Computer and Information Science Serie, D. Palmer-Brown et al eds (Springer, Londres, 2009).
- C31. J. Bongono, N. Azema, A. Johannet, P. Gaudon. *Determination of the Agglomerates Characteristics in Aqueous Suspensions*. In Science et Technologies des Poudres et Matériaux Frittés (STPMF 2009) (Montpellier, 2009).
- C32. L. Kong A Siou, A. Johannet, S. Pistre, V. Borrell. *Flash Floods Forecasting in a Karstic Basin using Neural Networks: the Case of the Lez Basin (South of France)*. International Symposium on Karst – ISKA (Malaga, 2010). In Advances in research in karst media. Andreo et al eds (Springer, 2010).

REVUES DE VULGARISATION

- P1. S. Danieau, E. Touraud, A.L. Courbis, A. Johannet. *Gestion des sites pollués : outil d'évaluation simplifiée des risques et choix d'une filière de réhabilitation*. In revue Préventique-Sécurité, vol. 33, pp. 83-88, (Editions Préventique, 1997).

COMMUNICATIONS ET POSTERS SANS ACTES

- CP1. A. Johannet. *Et si les robots pouvaient apprendre leur comportement de manière autonome ?* Communication à la journée Robotique du GIS Sciences de la Cognition, juin 1997, (Marseille, France).

- CP2. P. Massotte, P. Couturier, A. Johannet. *Réseaux de neurones et auto-organisation dans les systèmes de production distribués*. Communication aux Journées Nouvelles Technologies de l'Information et de la Communication 1998 (Ecole des Mines de Paris, 1998).
- CP3. S. Eurisouké, A. Johannet, P.A. Ayral, B. Vayssade. *Application des réseaux de neurones à la prévision opérationnelle des crues éclair*. Poster au Colloque de la Société Hydrotechnique de France "150ème anniversaire des crues de 1856" (Paris 2006).
- CP4. J. Bongono, N. Azema, A. Johannet, P. Gaudon. *Settling of Cohesive Powders: an Analysis Using Concentrate Suspensions Analyser*. Poster aux XIème Journées de la Matière Condensée, (Strasbourg, 2008).
- CP5. M. Toukourou, P.A. Ayral, A. Johannet, G. Dreyfus. *Prévision des crues du Gardon d'Anduze par réseaux de neurones : rôle de l'architecture*. Poster aux Journées de l'Observatoire Hydro-Météorologique Cévennes-Vivarais (Nîmes, 2008).
- CP6. J. Bongono, N. Azema, A. Johannet, P. Gaudon. *Determination of the Agglomerates Characteristics in Aqueous Suspensions*. In Poster aux Journée de la Recherche de l'Ecole Doctorale de l'Ecole des Mines de Saint Etienne (Saint Etienne, 2009).
- CP7. L. Kong A Siou, K. Cros, A. Johannet, V. Borrell, S. Pistre. *Prise en compte de l'hétérogénéité géologique dans la modélisation pluie-débit par réseaux de neurones. Cas du karst du Lez*. Communication aux Journées de l'Association Française de Karstologie (Habkern, 2010).

Projet de recherches à 4 ans

Comme indiqué dans le résumé de mes activités de recherche, le fil directeur de ma démarche est l'application des méthodes d'apprentissage artificiel, notamment des réseaux de neurones, à des systèmes complexes, mal connus, qu'ils soient naturels ou artificiels, en interaction avec un environnement naturel. Mes recherches prévues dans les 4 années à venir vont s'appuyer sur cette démarche et la décliner dans plusieurs projets pour répondre à plusieurs questions.

Caractéristiques très particulières des signaux en hydrologie

Dans de nombreux travaux, le choix du critère qui permet de mesurer la qualité d'un modèle est adapté à l'objectif particulier visé par le modèle. Or, fort peu de travaux s'intéressent à modifier le critère minimisé durant l'apprentissage. Ainsi, prenant en compte le fait qu'en hydrologie les mesures de précipitations comme de débits, ainsi que le bruit associé, suivent une distribution très éloignée de la distribution normale, nous allons étudier les liens qui existent entre la fonction de coût et les distributions statistiques des signaux d'entrée et de sortie. Plusieurs pistes sont envisagées : celle qui consiste à effectuer une transformation non linéaire des signaux d'entrée et de sortie a déjà été initiée par d'autres auteurs, mais mérite d'être revisitée avec des transformations statistiques ; celle qui consiste à adapter la fonction de coût est plus originale. Nous entreprendrons les deux approches.

Approfondissement des méthodes de régularisation

Les travaux réalisés sur les données hydrologiques montrent que, pour ces données et pour le type de modèle que nous avons mis en œuvre, la régularisation par arrêt précoce est généralement plus efficace que celle par modération des poids. En nous inspirant des travaux réalisés par L. Ljung, nous comparerons, en fonction des méthodes de régularisation, les valeurs obtenues respectivement, par les paramètres du réseau, par la matrice Jacobienne et par la matrice Hessienne, afin d'étudier les relations qui lient chacun de ces trois types grandeurs et les propriétés de généralisation des modèles.

Bassin versant normalisé

Le bassin versant normalisé est proposé dans une approche dite de *régionalisation* : un modèle est conçu pour un bassin versant jaugé, puis après la normalisation des précipitations et des débits tant en intensité qu'en temporel, un bassin versant *normalisé* à intérêt *régional* est conçu. Dans le cadre du projet BVNE²⁴, nous étudierons les différentes transformations de normalisation qui ont un sens en hydrologie (tant pour le temps de réponse du bassin versant que pour la normalisation par rapport à sa superficie ou ses caractéristiques topographiques), ainsi que les limites de régionalisation du bassin normalisé ainsi conçu.

²⁴ BVNE : Bassin Versant Numérique Expérimental : projet du SCHAPI dont l'objectif est de faire collaborer plusieurs équipes scientifiques autour d'un même objectif à l'aide d'une même base de données.

Modélisation semi-physique et boîtes transparentes

Les boîtes transparentes seront mises à profit dans le projet FLASH²⁵ pour évaluer différentes hypothèses sur la capacité d'infiltration des sols lors des épisodes pluvieux intenses du Piémont Cévenol. Elles seront également utilisées pour estimer et prévoir le niveau de la nappe souterraine du bassin versant de la Somme. Par ailleurs, en s'inspirant du modèle hydrodynamique des karsts de M. Alain Mangin, les boîtes transparentes seront utilisées afin d'estimer le niveau de remplissage du karst. Les applications sont alors immenses tant pour l'estimation des ressources en eau que pour l'écrêtage de crue en cas d'orage violent.

Adaptativité et assimilation de données

Le projet FLASH prévoit d'étudier l'application de l'assimilation de données. À cette fin nous étudierons comment rendre adaptatifs les paramètres du modèle, ce qui est une démarche déjà étudiée ; de manière plus innovante, nous assimilerons également les grandeurs de précipitations afin de compenser les erreurs et approximations de mesure qui peuvent être très importantes.

²⁵ FLASH : Flood forecasting with machine Learning, data Assimilation and Semi-pHysical modeling.

Synthèse des activités d'enseignement

Enseignant-chercheur depuis 1985, mes activités d'enseignement sont assez diverses, tant sur les contenus que sur les méthodes.

Travaux dirigés et Travaux pratiques

ESPCI (1985-1990) Electronique en première année : TD, préceptorats et TP.

EMA (1991-2011) TD en : électronique (1991-2006), automatique (1998-2011), réseaux de neurones (1991-2011), électronique physique (1997-2000), capteurs (1994-1999), traitement du signal (2000-2011) ; TP de : électronique (1991-1999), physique (1995-1999), réseaux de neurones (1991-2011).

Cours magistraux

- EMA

Pour tous les cours magistraux, j'ai rédigé un polycopié détaillé. Sont indiqués dans ce qui suit l'année d'étude où est dispensé l'enseignement, le nombre moyen d'étudiants, les années où cet enseignement a eu lieu ; en effet de nombreuses refontes des enseignements font que les cours apparaissent puis disparaissent ou sont repris par des collègues lors de leur arrivée à l'Ecole.

Electronique (4^{ème} année, 30 élèves ; 1991-1994).

Architecture de l'ordinateur (2^{ème} année, 150 élèves ; 1995-1998).

Automatique (1^{ère} année, 120 élèves ; 1998-2011).

Réseaux de neurones (3^{ème} année, 30 élèves ; 1991-2010).

Complexité (3^{ème} année, 30 élèves ; 1999).

- DEA SIAM de l'Université Montpellier II

Réseaux de neurones (1995 et 1996).

- DEA de Productique et d'Informatique de l'Université d'Aix Marseille III

Réseaux de neurones (1998).

Encadrement de projets (enseignement et recherche)

- EMA, en moyenne par année

Deux projets longs internes à l'EMA par an : projet d'un groupe de trois élèves en 3^{ème} année (temps élève de plus de 100 h à l'emploi du temps).

Cinq mini-missions de mathématiques (depuis 2000) : trois élèves durant 1 semaine.

Accueil de stagiaires étrangers (russes, espagnols, indiens, allemands ...) dans le cadre d'échanges internationaux.

Suivi de 2 missions (depuis 2000 : 3 élèves en situation professionnelle en entreprise durant 5 semaines ; vérification du bon déroulement de l'étude).

Pédagogies innovantes

Ma conviction, forgée aux feux des tableaux noirs et des amphithéâtres, est que le temps de l'expert qu'est l'enseignant devrait être réservé aux approfondissements du cours et aux discussions avec les étudiants plus qu'à l'explication des bases qui constitue parfois une part non négligeable des enseignements. C'est pourquoi, avec mon collègue Daniel Diep j'ai initié une modification profonde de la pédagogie de l'enseignement d'automatique en première année de formation initiale (120 élèves en 2000) ; j'ai également participé à la formation à distance (par Internet) en électronique, pour un public d'étudiants salariés (2001-2008).

Automatique en formation initiale. Le cours magistral en amphithéâtre a été supprimé au profit d'un pilotage pédagogique renforcé avec des contrôles continus rendus par groupes de 3 élèves à chaque séance de TD. Les contrôles continus ont pour vocation de faire travailler les élèves sur les points importants du cours, par ailleurs fourni sous forme d'un polycopié détaillé (100 pages environ) comprenant des apports théoriques méthodologiques et des exercices simples d'application et de stimulation du questionnement des étudiants. En place et lieu du cours, un espace question est aménagé pour les étudiants qui le souhaitent et prennent un rendez-vous avec l'enseignant. L'efficacité de cette méthode pédagogique est validée après 9 années d'exercice.

Électronique à distance en formation continue. Le cours est remplacé par un polycopié détaillé. Les TD ont lieu le soir par internet chaque semaine pendant la durée de l'enseignement. Les TP sont réalisés à l'occasion des examens chaque trimestre (regroupement physique des étudiants qui habitent parfois à plusieurs centaines de km de l'école, voire à l'étranger). Compte tenu des limitations de la bande passante par internet, une méthode pédagogique originale a été déployée durant les TD pour stimuler le travail des étudiants. Cette activité a donné lieu à 2 communications internationales [C26][C28].

Responsabilités pédagogiques

Coordination de l'enseignement d'automatique en tronc commun (1994-1999)

Responsable adjoint de l'équipe pédagogique de la 2^{ème} année (1999-2005)

Animations de groupes de travail et rapports internes ayant trait à la pédagogie

Groupe de travail sur l'évaluation des élèves en 1992-1993. Définition et intégration au règlement de scolarité de la notion de "groupe de matières". Rédaction des comptes-rendus.

Groupes de travail sur l'évaluation des élèves en 1997-1998. Animation (et rédaction des comptes-rendus) du groupe de travail sur les cours de base ; définition originale et proposition

de la "grille de contenus et d'évaluation". Participation aux groupes centrés sur les cours au choix et l'évaluation des TP.

Groupes de travail sur la réforme entrepreneuriale en 1999.

Groupe de travail sur l'efficacité des enseignements en 2004. Animation du groupe, rédaction des comptes rendus et du rapport de synthèse pour le Conseil de Direction de l'Ecole.

Jurys de thèses et encadrements

Participation à des jurys de thèses

- *Pierre Couturier*, soutenue le 16 juillet 1997. Thèse de doctorat de l'INSA de Lyon en spécialité : Automatique Industrielle. «Commande par réseaux de neurones : application au contrôle d'un préhenseur électropneumatique». Directeur de thèse : Monsieur Maurice Bétemp.
- *Carole Dautun*, soutenue le 14 décembre 2007. Thèse de doctorat de l'Ecole Nationale Supérieure des Mines de St Etienne en spécialité : Science et Génie de l'Environnement. « Contribution à l'Etude des crises de grande ampleur : connaissance et aide à la décision pour la Sécurité Civile. ». Directeur de thèse : Monsieur Gilles Dusserre.
- *Mohamed Toukourou*, soutenue le 10 décembre 2009. Thèse de doctorat de l'Ecole des Mines de Paris en spécialité : Informatique Temps Réel, Robotique et Automatique : «Application de l'apprentissage artificiel aux prévisions des crues éclair». Directeur de thèse : Monsieur Gérard Dreyfus.
- *Julien Bongono*, soutenue le 3 septembre 2010. Thèse de doctorat de l'Ecole Nationale Supérieure des Mines de St Etienne en spécialité : Science et Génie des Matériaux. «Caractérisation des suspensions par des méthodes optiques. Modélisation par Réseaux de Neurones». Directeur de thèse : Monsieur Pierre Gaudon.

Co-encadrement de thèses en cours

- *Line Kong A Siou* (2008-2011), Montpellier II, Ecole Doctorale SIBAGHE « Modélisation des crues de bassins karstiques par réseaux de neurones ». Directeur de thèse : M. Séverin Pistre.
- *Audrey Bornancin-Plantier* (2009-2012), Paris VI, Ecole Doctorale EDITE. «Application de l'apprentissage artificiel à la modélisation systémique de la chaîne hydrométéorologique pour la prévision des crues éclair ». Directeur de thèse : M. Gérard Dreyfus
- *Guillaume Artigue* (2009-2012), Montpellier II, Ecole Doctorale SIBAGHE. « Prévision des crues éclair par réseaux de neurones, généralisation aux bassins versants non jaugés ». Directeur de thèse : M. Séverin Pistre.

Master 1

- *Guillaume Artigue* (2007). "Les réseaux de neurones formels : application aux crues éclair du bassin versant de la Cèze". Université Montpellier II. Master Géosciences.
- *Coralie Guillot* (2010). "Détermination de paramètres spatio-temporels de caractérisation des bassins versants (multi échelles – multi sites) à l'aide de la modélisation hydrologique". Université de Montpellier II. Département des Sciences de la Terre, de l'Eau et de l'Environnement, mention Sciences Pour l'Environnement.

Master 2, DEA ou Mastère professionnel

- *Jean Louis Zorer* (1986). "Etude du réseau de Hopfield". Université Pierre et Marie Curie. DEA d'électronique.
- *Gilles Lohéac* (1987). "Règles Locales d'apprentissage pour les réseaux de neurones formels". Université Pierre et Marie Curie, DEA d'électronique.
- *Jean Philippe Amouroux* (1996). "Etude de la construction d'un classifieur par réseaux de neurones : application au traitement d'images satellites". Université de Montpellier II. DEA SYAM.
- *Stéphane Danieau* (1996). "Gestion des sites pollués : outils d'évaluation des risques et méthodologie de choix d'une filière de traitement". LGEI- EMA. Mastère spécialisé en Sécurité Industrielle et Environnement.
- *Cuq Jérôme* (1997). "Identification de processus dynamique par réseaux de neurones". Université de Montpellier II. DEA SYAM.
- *Sarah Eurisouké* (2006). "Prévision des crues par réseaux de neurones formels". Université de Poitiers. Master Professionnel Géotechnologie Expérimentale.
- *Kévin Cros* (2009). "Prise en compte du karst dans la modélisation par réseaux de neurones appliquée au Lez". Université Pierre et Marie Curie. Master 2 Sciences de l'Univers, Environnement, Ecologie, Parcours Hydrologie-Hydrogéologie.

Résumé

Ce mémoire d'Habilitation à Diriger les Recherches présente de manière synthétique les recherches effectuées sur la modélisation par apprentissage statistique de systèmes naturels ou en interaction avec un environnement naturel. La spécificité de l'apprentissage est tout d'abord discutée en relation avec le calage et permet d'introduire les notions d'identification universelle et de dilemme biais-variance qui sont ensuite approfondies dans le mémoire. Ces notions sont illustrées en relation avec la problématique de la synthèse d'un modèle de simulation ou de prédition. Plusieurs illustrations sont présentées comme l'apprentissage de comportement d'un robot hexapode, la synthèse du contrôleur d'un préhenseur pneumatique et la modélisation d'hydrosystèmes tels les karsts ou les bassins versants rapides. Ces derniers, emblématiques des défis que la science doit permettre d'aborder, ont en commun la disponibilité de bases de données observées depuis plusieurs décennies, la non-linéarité des processus impliqués dans ces phénomènes, la difficulté à mesurer les variables d'état et la présence d'un bruit de mesure considérable. Face à ces difficultés, ce mémoire présente comment les méthodes de régularisation ont été revisitées et propose une démarche originale de modélisation semi physique, les *boîtes transparentes*, qui permet de valider physiquement le modèle tout en approfondissant la connaissance des phénomènes étudiés.

Abstract

This “Habilitation à Diriger les Recherches” report presents a synthesis of research on the modeling of natural systems, or systems in interaction with a natural environment, by machine learning. The specificity of training is first discussed in relation to the calibration and leads to the introduction of the concepts of universal identification and bias-variance dilemma which are then detailed. These concepts are illustrated with regards to the synthesis of a model dedicated to simulation or prediction. Several illustrations are presented such as the training of several behaviors by a mobile robot, the synthesis of a gripper pneumatic controller, and finally the modeling of hydrosystems such as karsts or rapid watersheds. These iconic challenges have in common the availability of databases for several decades, the nonlinearity of the processes involved in these phenomena, the difficulty to measure the state variables, the presence of a considerable noise on the measurements. In order to deal with these difficulties, this report presents how the regularization techniques were reviewed and proposes an original method of semi-physical modeling, *the transparent boxes*, which allows the physical validation of the model and the deepening of the knowledge one gets about the studied phenomena.

