

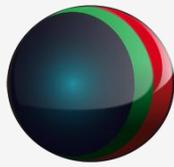


Réseaux de neurones pour modèles dynamiques - Exemples en hydrologie -

patrice.kiener@inmodelia.com

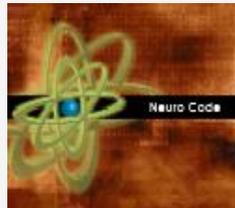
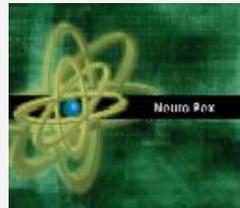
Tel : +33.9.53.45.07.38

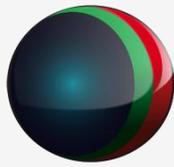
LMCS – Pôle universitaire Léonard de Vinci – 7 décembre 2012



A propos d'InModelia :

- Basé à Paris depuis 2009 – 1,5 personne
- Editeur – Revendeur de logiciels de réseaux de neurones
- Prestataire de conseil, études, formation (ESPCI), ...
- Expertise :
 - Plans d'expériences et réseaux de neurones statiques
 - Réseaux de neurones dynamiques
 - Graph Machines pour QSAR et QSPR (chimie, biochimie)
- Logiciel open source : R
- Logiciels édités par Netral : Neuro One, Neuro Pex, Neuro Code, NDK





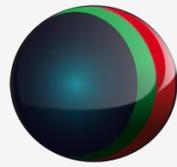
Modéliser / Simuler un phénomène pour lesquels le praticien :

- Suppose qu'il y a une relation de cause à effet entre des entrées et une ou plusieurs sorties
- Ne connaît pas de loi physique ou de modèle de connaissance a priori
- Aimerais bien trouver un modèle représentatif...
- Dispose de données expérimentales

→ **Modèles « boîte noire » par apprentissage = statistique**

Démarche classique des modèles par apprentissage :

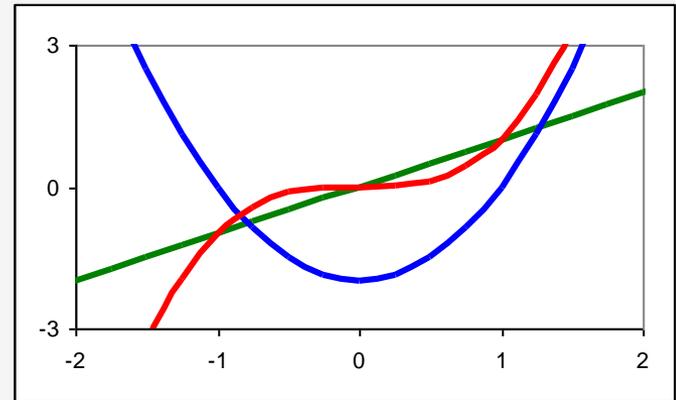
- Modèles **linéaires** → régression sur des polynômes (classif : rég. logistique)
- Modèles **bilinéaires** → régression PLS
- Modèles **non-linéaires** → régression sur des réseaux de neurones
- Modèles **non-paramétriques** → krigage, machines à vecteurs supports, etc...
- Autres techniques d'optimisation → algorithmes génétiques, etc...



Modèles boîte noire = Combinaison de fonctions simples

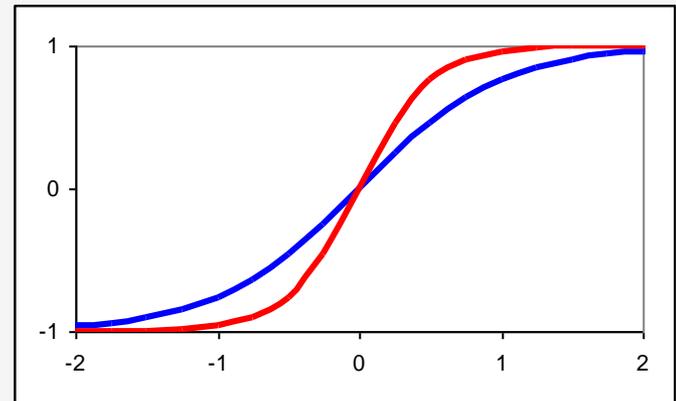
Polynômes

- Addition de fonctions simples linéaires en les coefficients : x , x^2 , x^3 , x^{\dots}
=> plans, quadriques, cubiques
=> courbure nulle ou uniforme dans l'espace



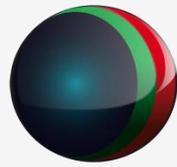
Réseaux de neurones

- Addition de fonctions simples non-linéaires en les coefficients :
 - Tangente hyperbolique sigmoïde, arctangente, etc.
=> courbure variable (ici $th(X)$ vs $th(2X)$)



Prix à payer :

- Le nombre de coefficient d'un polynôme ou d'un réseau de neurones est toujours très important, typiquement de **10 à 60 coefficients**, ce qui est bien supérieur à un modèle de connaissance

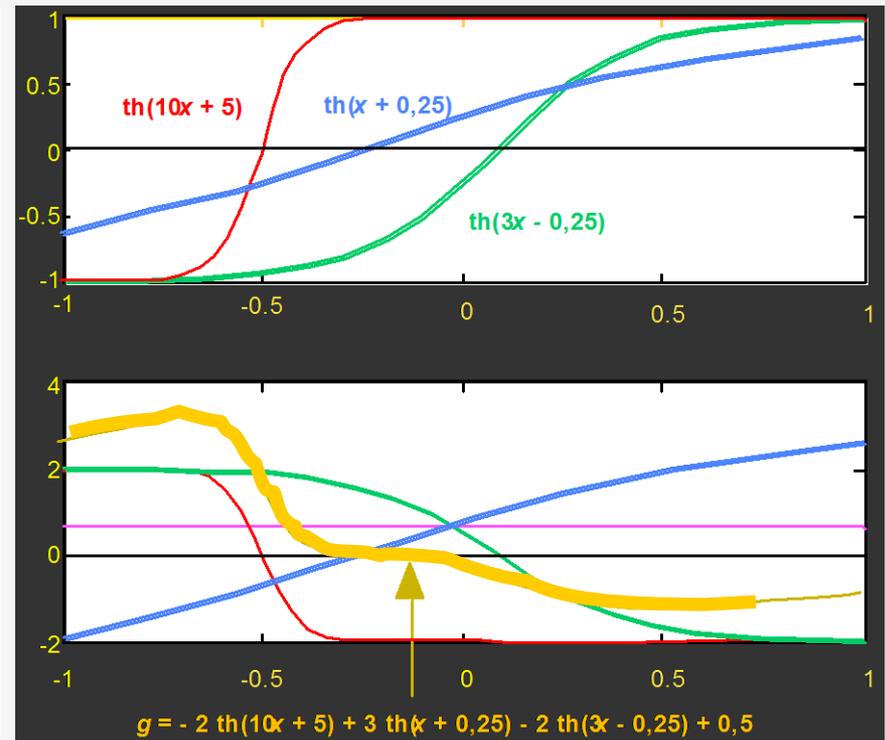
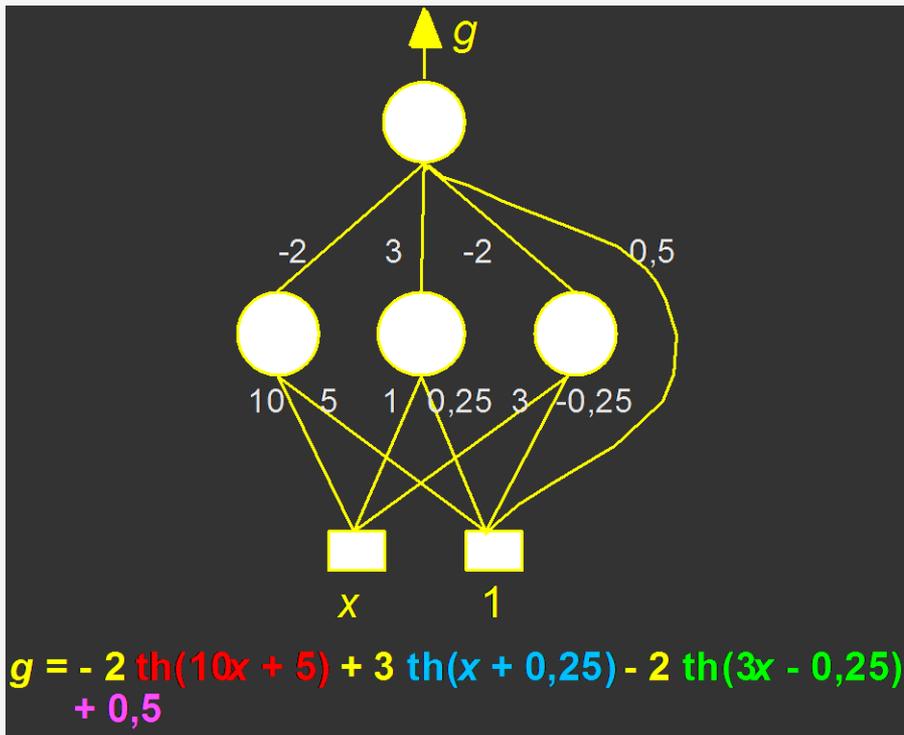


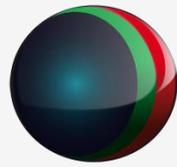
Qu'est-ce qu'un réseaux de neurones ?

Une combinaison de plusieurs neurones

Classiquement :

- une couche d'entrées
- une couches de neurones non-linéaires
- une couche de sortie

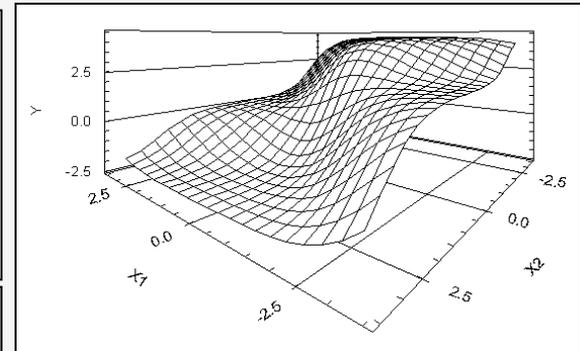
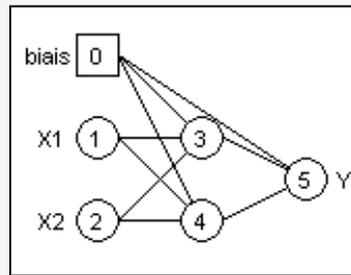




Réseaux de neurones statiques

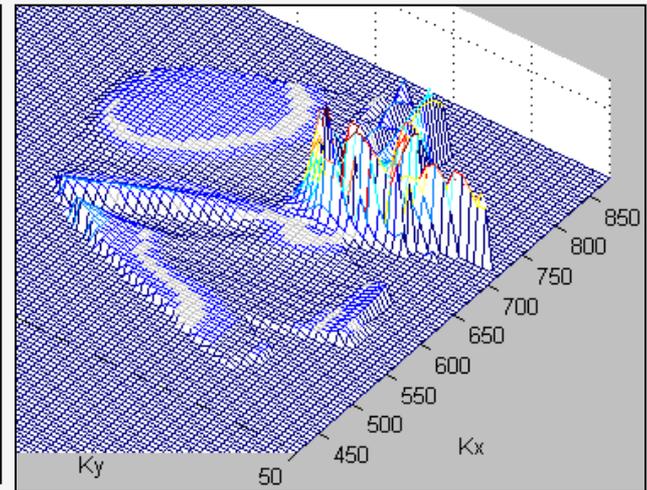
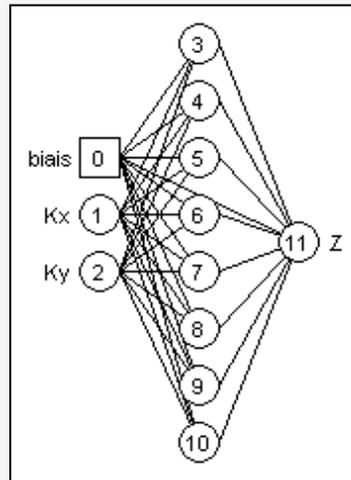
EXEMPLES de réseaux de neurones à 2 entrées et 2 ou 8 neurones cachés

- 2 neurones cachés :
(9 coefficients)



$$Y = \theta_1 + \theta_2 \text{th}(\theta_4 + \theta_5 X_1 + \theta_6 X_2) + \theta_3 \text{th}(\theta_7 + \theta_8 X_1 + \theta_9 X_2)$$

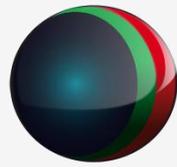
- 8 neurones cachés :
(33 coefficients)
Est-ce du surapprentissage ?



$$Z = \sum_{i=0}^8 b_i \left(\text{th} \sum_{j=0}^2 a_{ij} X_j \right)$$

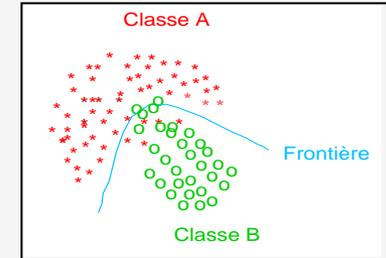
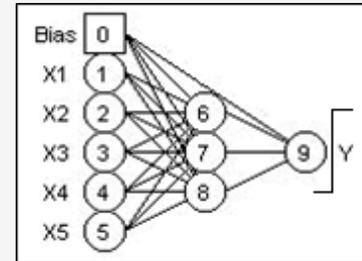
InModelia a déjà construit des modèles à 15 entrées indépendantes.

Si plusieurs sorties, on construit un modèle par sortie et on fusionne après apprentissage

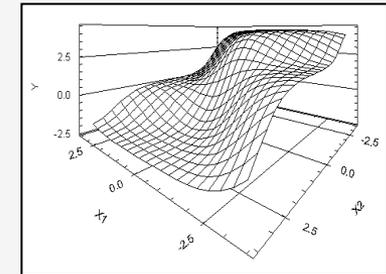
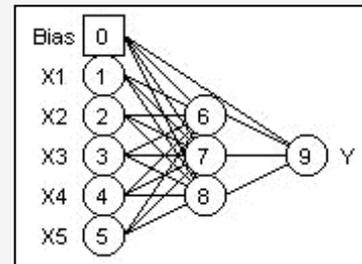


4 types de réseaux de neurones

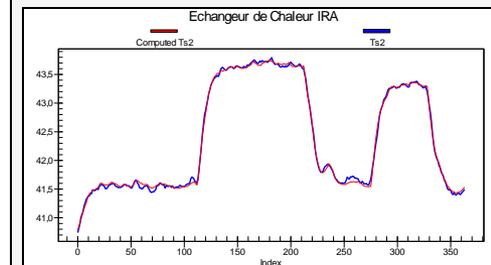
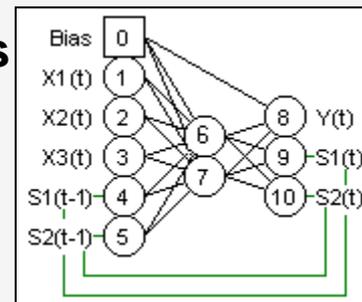
RN statique de classification
- appartenance classe A ou B



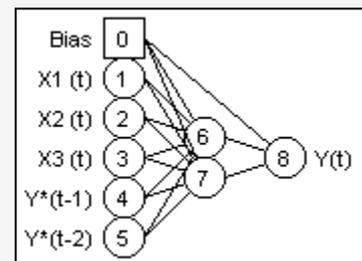
RN statique d'estimation
- surface de réponse (le plus fréquent)

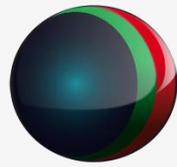


RN dynamiques pour séries chronologiques
- RN dynamiques sortie / entrée (modèle NARMAX)
- RN dynamiques d'état



RN faussement dynamique
- RN statique + série temporelle (Matlab)

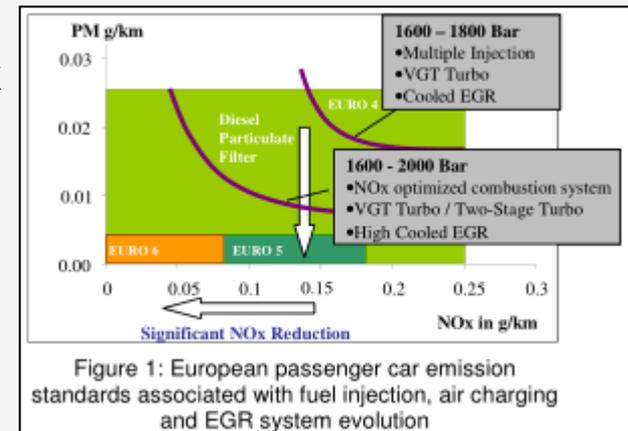




RN statique au lieu de dynamique : Injection diesel

Modélisation de l'émission des NOx en sortie d'un pot d'échappement :

- Delphi Diesel, SIA 2007 et Rouen 2008
- Enjeu : diviser par 2 puis 4 les émissions de NOx
- Suppose un modèle précis en régime stabilisé et en régime transitoire

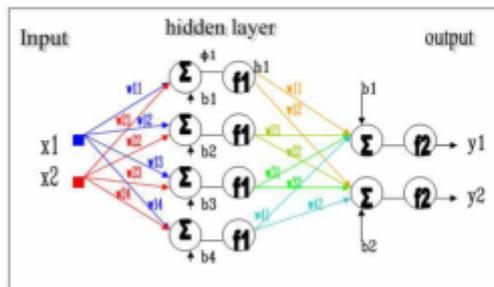


Réseaux de neurones :

- Modèle statique multi-sortie pour étudier un phénomène transitoire !!!....

To meet the increasingly strict emission regulations of the future, robust, dynamic calibration techniques will be required. For this reason, Delphi undertook to develop a dynamic, multivariable emissions model using neural networks. This new model improves the accuracy of emission prediction and opens new possibilities in the diesel vehicle dynamic calibration optimisation process.

3.3 Neural network model construction

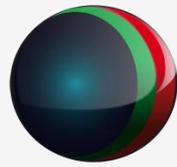


The input parameters are as follows:

- 13 engine parameters including injection quantities and timing (2 pilots, 1 main injection, and 1 after injection) rail pressure, air flow, boost pressure, swirl position, throttle position
- Inlet air temperature, coolant temperature and engine cycle speed

The outputs are:

- NOx / HC /CO emissions and smoke opacity
- Noise and CO2 emissions,



RN statique au lieu de dynamique : Injection diesel

Résultats :

- De correct à franchement mauvais
- Les réseaux de neurones ont été abandonnés

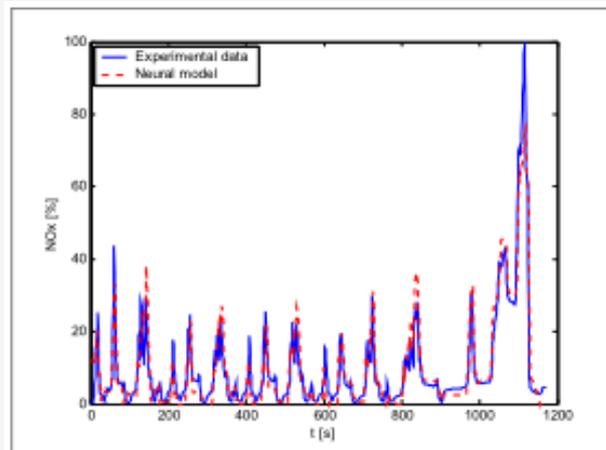
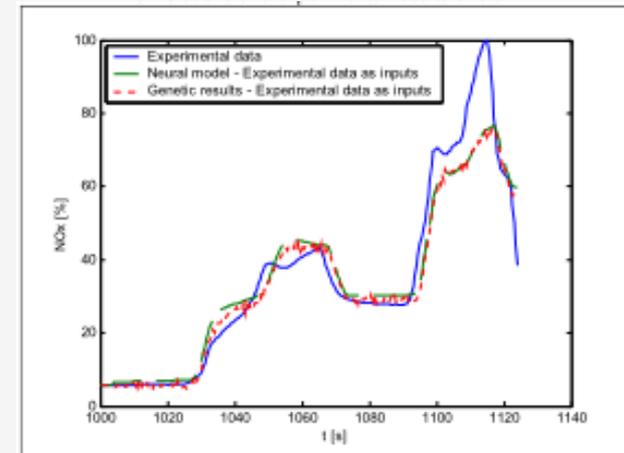
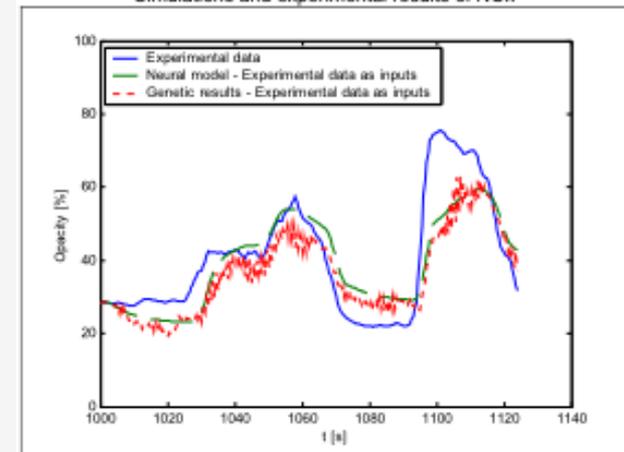


Figure 13: Comparison between neural model of NOx and experimental data over a complete cycle NEDC.



Simulations and experimental results of NOx

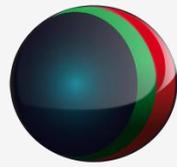


Simulations and experimental results of Opacity

Figure 18: Comparison between pollutants' emission obtained by experiment and by the genetic algorithm.

Commentaires :

- Il ne faut pas utiliser la Neural Toolbox de Matlab pour modéliser des phénomènes transitoires !!!
- Un mauvais outil peut donner des contre-résultats catastrophiques.

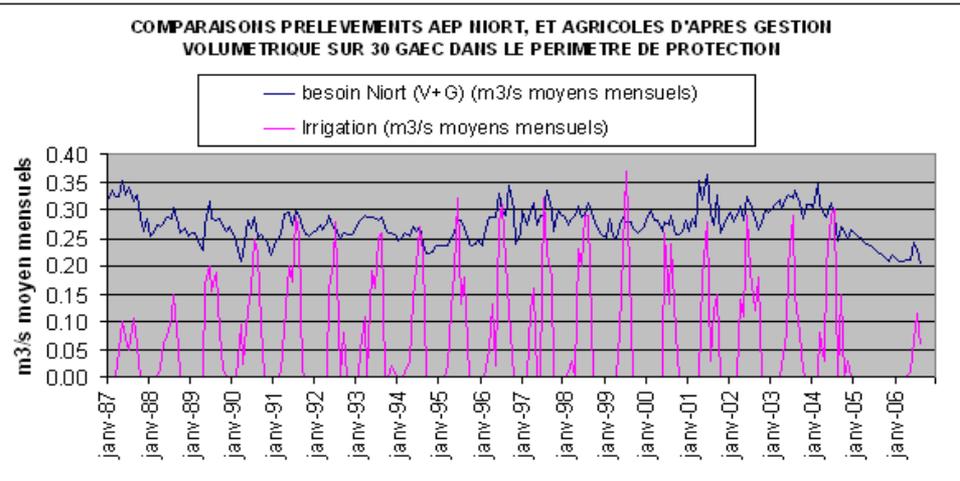
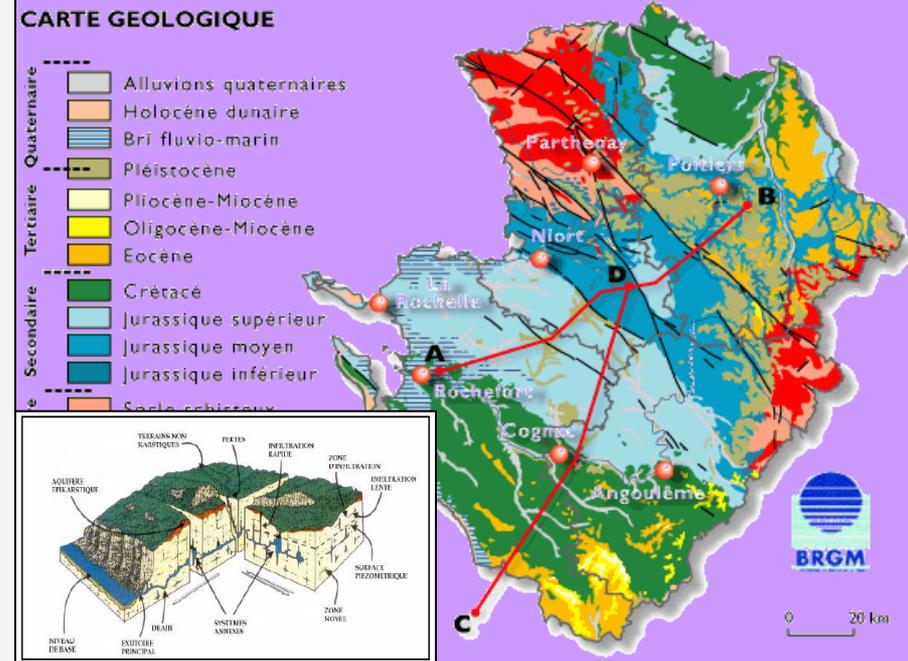
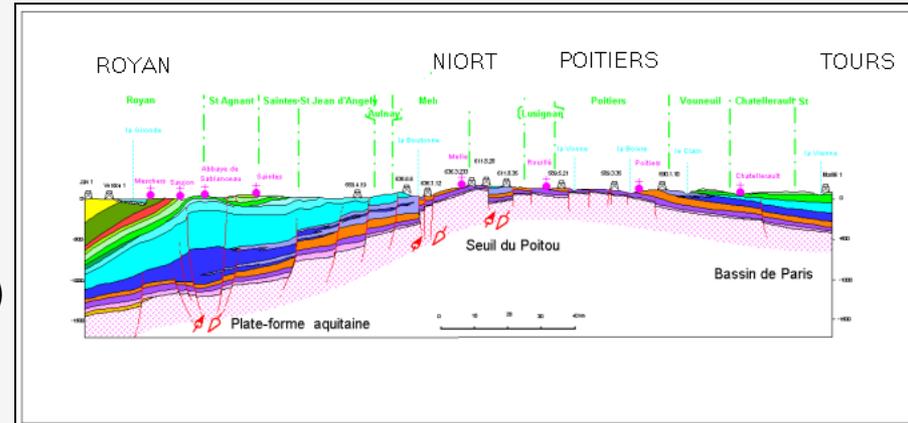


Modèle dynamique : Ville de NIORT (1)

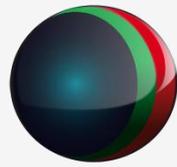
Prédiction du niveau d'eau de la source pour éviter une pénurie d'eau en été.

Compétition intense entre :

- consommation humaine (ville de Niort)
- irrigation (maïs, 30 fermiers)



5 années à risque au cours des 10 dernières années

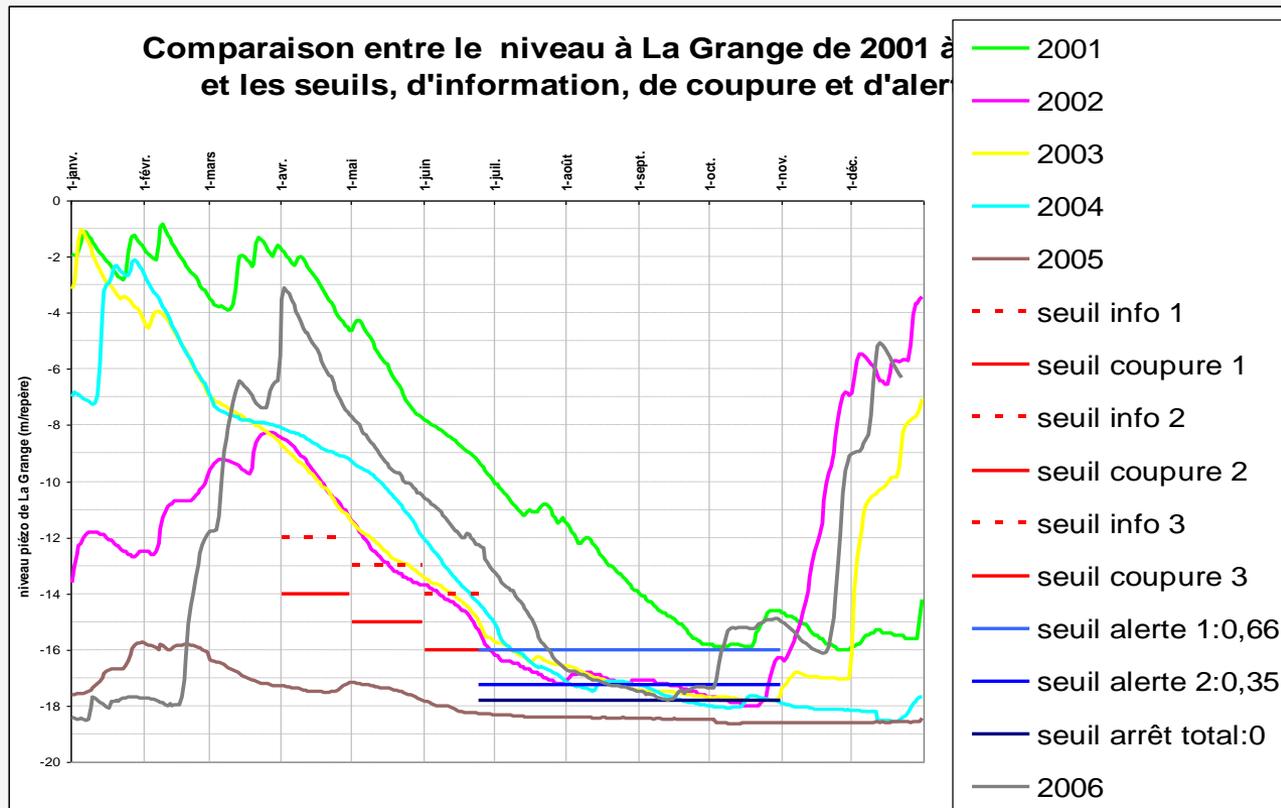


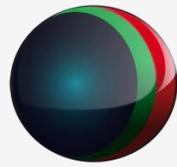
Modèle dynamique : Ville de NIORT (2)

Le niveau d'eau est au plus bas en août et septembre.

5 années à risque au cours des 10 dernières années.

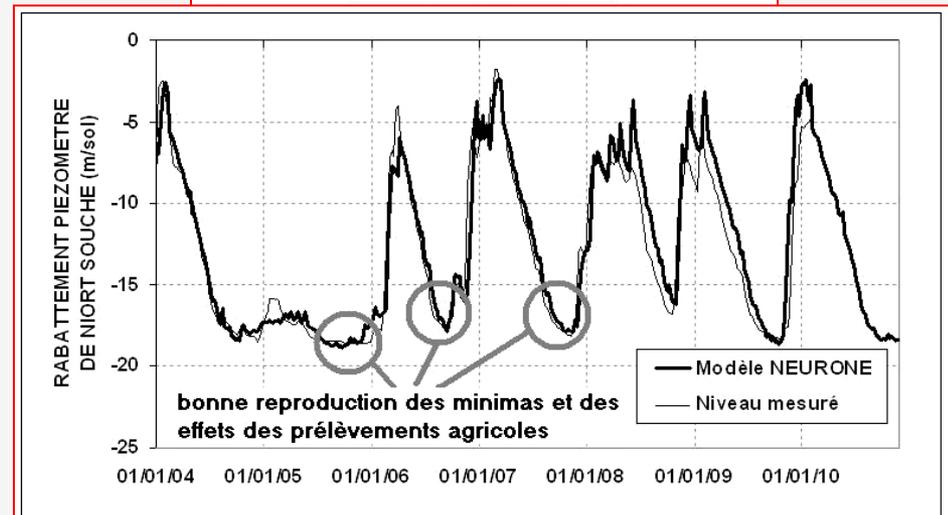
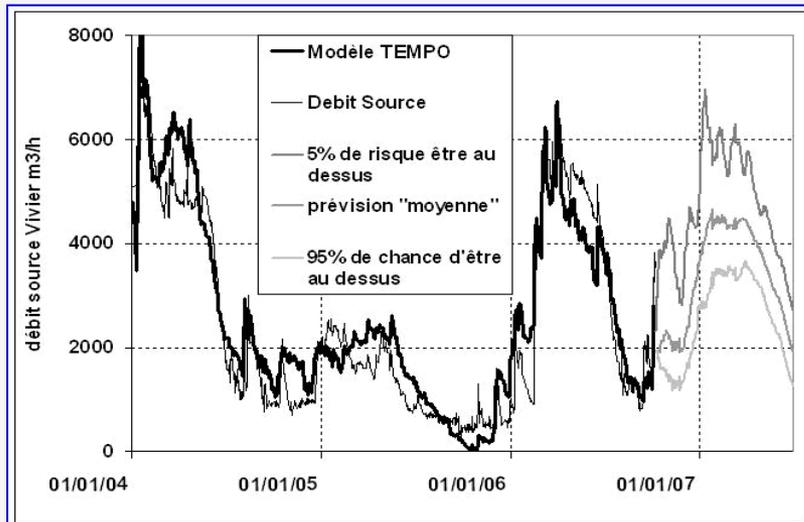
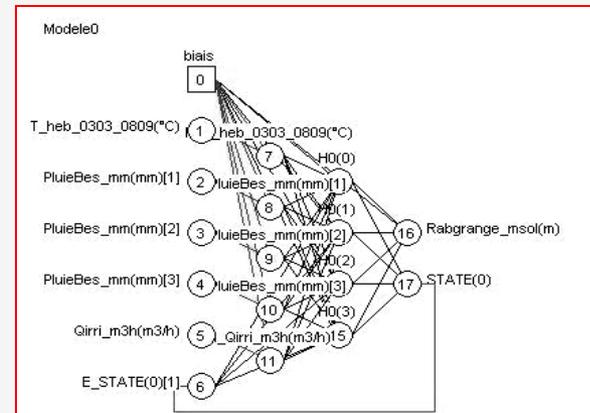
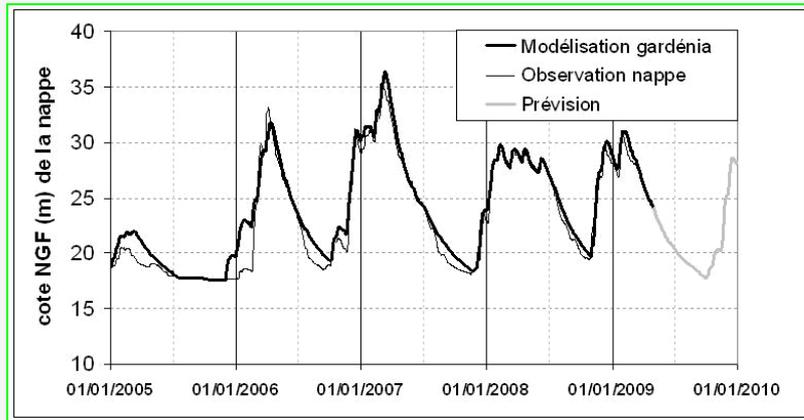
Pouvons-nous prédire le niveau d'eau quelques mois/semaines à l'avance ?

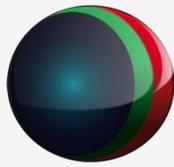




Modèle dynamique : Ville de NIORT (3)

Plusieurs modèles testés pour prédire le niveau d'eau sur une base hebdomad. : **Gardenia** (BRGM), **Tempo** (BRGM). **Neuro One** (Netral-InModelia) est le meilleur et peut prédire 2 mois à l'avance



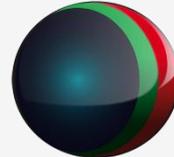


Maintenance préventive des capteurs du réseau des eaux usées :

- Réseau de 170+ capteurs reliés à une base de données centralisée
 - Hauteur d'eau
 - Vitesse d'écoulement
- Réseaux amont-aval avec quelques interconnexions entre les réseaux
 - Double sens d'écoulement selon les charges respectives
 - Phénomène de siphon
- Acquisition des données sur évènement (intermittence)

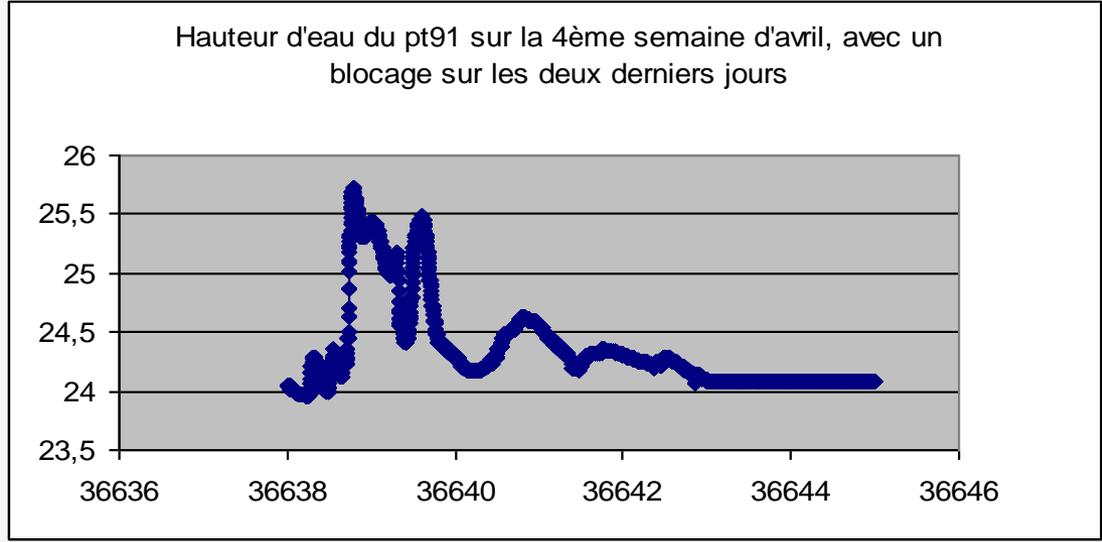
→ **Anticiper les dérives et les blocages des capteurs**

= Construire un modèle de l'écoulement des eaux

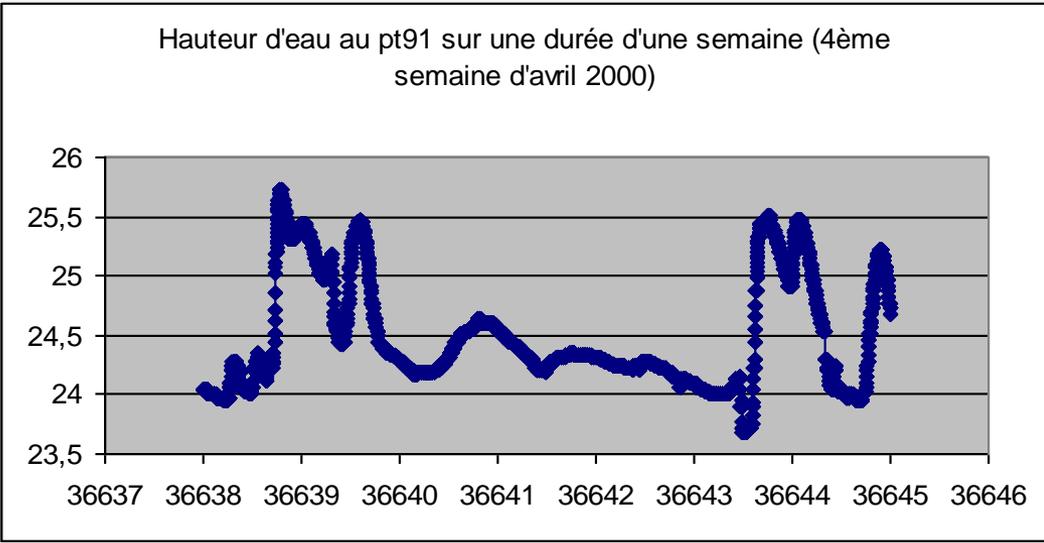


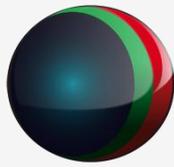
Exemple Capteur 91 :

Blocage du capteur de hauteur d'eau



Données reconstituées





Modèles dynamiques similaires à ceux de Niort

- Choix des entrées
- 2 ou 3 neurones cachés
- Un bouclage pour les modèles simples (ordre 1)
- Deux bouclages pour les modèles à siphon (ordre 2)

Les difficultés sont ailleurs

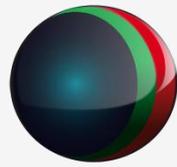
Abondance / Pénurie de données :

- Reconstitution des jeux de données, synchronisation
- Recherche de la fréquence d'échantillonnage optimale

L'écoulement d'eau introduit un retard variable selon l'intensité des pluies

- Oblige à se caler sur la vitesse la plus rapide
- Le réseaux de neurones s'adapte **automatiquement** au retard variable

→ **Le point fort des réseaux de neurones dynamiques**



Réseaux de neurones et commande (1)

Journée InModelia – SEE – SFGP – ESPCI du 11 janvier 2012

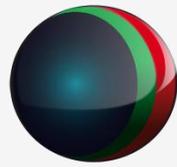
- Journée « Réseaux de neurones pour le contrôle et la surveillance des procédés »
<http://www.inmodelia.com/journee-rncsp.html>

Panorama de plusieurs modèles dynamiques / commande neuronale :

- Réseaux de neurones dans commande à modèle interne ou commande prédictive
- Peu de sujets, encore moins de résultats
- Très beaux résultats (Rhodia / Bluestar Silicones) quasi-opérationnels, mais en concurrence avec des solutions plus simples
- Des échecs liés à une méconnaissance de la théorie / utilisation de mauvais outils lors de la phase exploratoire

Opinion de Jacques Richalet :

- Le père de la commande prédictive => Vive la commande prédictive !
- Est en faveur des réseaux de neurones
- Mélanger réseaux de neurones (pour la partie modèle) et commande prédictive quand le modèle est très non-linéaire



Réseaux de neurones et commande (2)

Commentaires d'expert (CNES) :

- Les RN sont de bons modèles non-linéaires (statique, dynamiques)
- La robustesse des réseaux de neurones est toujours discutable
- Spatial => Tests extrêmement poussés
- Extrapolation, etc... L'expert trouvera toujours une configuration pour tuer le RN
- Incompatible avec la certification

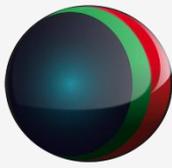
- La gestion des contraintes est non comprise dans le RN / commande neuronale
- Pour la gestion des contraintes, la commande prédictive est idéale

- Formation des experts : la commande prédictive a une base d'experts suffisante

Importance du matériel :

- Sur ordinateur, on peut faire beaucoup de choses
- Disponibilité des réseaux de neurones dynamiques dans les régulateurs et systèmes de contrôle-commande industriels (effort souhaité des fabricants)

Conclusion



Avantages :

- **Les réseaux de neurones dynamiques apportent des solutions là où il n'y a pas de modèles de connaissance**
- **Ne pas les confondre avec les modèles statiques**

Inconvénients :

- **Certification des modèles problématique (extrapolation)**
- **Toujours pas disponible dans les SNCC industriels (systèmes numériques de contrôle-commande) mais disponible sur PC**



Merci pour votre attention

patrice.kiener@inmodelia.com

Tel : +33.9.53.45.07.38

LMCS – Pôle universitaire Léonard de Vinci – 7 décembre 2012