



Utilisation des réseaux de neurones pour la prévision des dégagements de grisou en taille

Jean-Christophe Couillet

► **To cite this version:**

Jean-Christophe Couillet. Utilisation des réseaux de neurones pour la prévision des dégagements de grisou en taille. Journée technique CdF, Jun 1998, Hombourg-Haut, France. ineris-00972153

HAL Id: ineris-00972153

<https://hal-ineris.archives-ouvertes.fr/ineris-00972153>

Submitted on 3 Apr 2014

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.

*Journée Technique de Charbonnages de France,
Hombourg-Haut, le 3 juin 1998*

UTILISATION DES RESEAUX DE NEURONES POUR LA PREVISION DES DEGAGEMENTS DE GRISOU EN TAILLE

Jean-Christophe COUILLET,

Institut National de l'Environnement Industriel et des Risques (INERIS),
B.P. 2, 60550 Verneuil-en-Halatte, France.

1 INTRODUCTION

Les conditions actuelles d'exploitation se distinguent en autres de celles du passé par une mécanisation accrue autorisant un avancement rapide des chantiers. Parallèlement, l'approfondissement de l'extraction entraîne des zones d'influence de plus en plus étendues. Il en résulte au final des dégagements grisouteux à des niveaux relativement élevés ainsi que des fluctuations importantes.

Dans ce contexte, la conduite de l'exploitation doit se poursuivre avec une attention particulière pour garantir des conditions de sécurité optimales. La présence de grisou dans l'atmosphère des chantiers peut être suffisamment importante pour limiter le rythme de la production. L'exploitant doit de ce fait adapter sa production de façon à assurer le respect des teneurs limites réglementaires.

La prévision des dégagements grisouteux se révèle alors comme un outil particulièrement intéressant pour répondre au mieux aux objectifs de sécurité, mais aussi de productivité en permettant une répartition optimale des postes de production dans le temps.

Des méthodes de prévision du dégagement de grisou ont déjà été développées dans le passé.

Les premiers modèles se sont toutefois limités à la prévision du dégagement moyen de grisou [JEGER, 1980]. Ceux-ci n'intègrent pas les effets du temps et de la vitesse d'avancement des tailles et ne permettent donc pas le suivi des variations actuelles des dégagements grisouteux.

Les développements suivants se sont appuyés sur les techniques statistiques courantes de régression linéaire simple ou multiple [POKRYSZKA Z., TAUZIEDE C., 1994 ; COUILLET J.-C., POKRYSZKA Z., 1996 ; COUILLET J.-C., 1997]. Tout en tenant compte de la dynamique des dégagements grisouteux et des spécificités locales du chantier vis-à-vis du grisou, ces modèles ne sont malheureusement satisfaisants que pour la prévision au pas de temps hebdomadaire.

Le problème reste en effet plus complexe quant à la prévision à un pas de temps plus petit, à l'échelle de la journée ou du poste, essentiellement à cause de la non linéarité de la désorption et des écoulements du grisou. Or c'est justement cette connaissance du dégagement, au moins au pas journalier, qui permettrait une programmation plus efficace des chantiers.

Parallèlement, la recherche de nouvelles méthodes de modélisation plus performantes a conduit à l'identification d'une technique particulièrement novatrice, celles des réseaux de neurones. Une recherche a de ce fait été menée à l'INERIS pour appliquer cette technique en tant qu'outil de prévision des dégagements grisouteux en taille.

Il s'agit ici :

- d'exposer les principales bases sur lesquelles repose la technique des réseaux de neurones ;
- de présenter ensuite les développements majeurs destinés à optimiser la méthode de prévision ;
- d'illustrer enfin les travaux menés sur le cas concret d'une taille récemment exploitée aux Houillères du Bassin de Lorraine.

2 CONTEXTE ET PROBLEMATIQUE

2.1 POTENTIEL DE LA TECHNIQUE

La technique des réseaux de neurones est un outil de modélisation ayant aujourd'hui fait ses preuves dans de nombreux domaines (bancaire, militaire, météorologique...) en réponse à des problèmes aussi divers que ceux relatifs à la prévision, la classification, ou encore le traitement du signal.

Le potentiel de cette technique réside principalement en sa capacité à appréhender des lois non linéaires.

Il repose également dans sa faculté à apprendre par l'exemple, et à extraire à partir d'un échantillon de données, le phénomène physique à modéliser. Il n'est donc pas impératif de disposer des connaissances physiques du problème, exprimées habituellement par des équations mathématiques, pour le modéliser.

Ces éléments lui confèrent en plus une forte résistance à toute perturbation éventuelle des données de base (données en partie erronées ou bruitées) ainsi qu'une faculté d'adaptation à une évolution possible du phénomène physique.

En contrepartie, le système neuronal doit toutefois répondre à certains impératifs. Il suppose entre autres que l'on dispose d'un stock suffisant de données relatives au phénomène physique.

2.2 RESEAUX DE NEURONES ET DEGAGEMENTS DE GRISOU

Les mécanismes de la désorption du grisou et les lois de circulation du gaz dans les terrains rendent complexe voire impossible une mise en équation physique complète du dégagement grisouteux dans les chantiers.

Les règlements miniers imposent des mesures fréquentes et régulières relatives à l'exploitation et à la composition de l'atmosphère des chantiers, ce qui constitue une base de données précieuse quant à l'historique des chantiers exploités.

La technique des réseaux de neurones se révèle de ce fait comme l'outil adapté pour la modélisation des dégagements grisouteux. Des travaux de recherche étrangers [DIXON et al., 1995] identifiés sur ce sujet et les essais de faisabilité menés à l'INERIS sur quelques tailles lorraines ont par ailleurs confirmé ce potentiel [COUILLET J.-C., KOUNIALI S., 1997].

3 FONCTIONNEMENT GENERAL DES RESEAUX DE NEURONES

3.1 LE NEURONE FORMEL

La technique des réseaux de neurones s'inspire du fonctionnement de la cellule nerveuse. Le neurone biologique est constitué d'un corps cellulaire qui reçoit des informations par l'intermédiaire de ses dendrites et, si l'activité reçue dépasse un certain seuil, délivre une réponse par l'intermédiaire de son axone (figure 1).

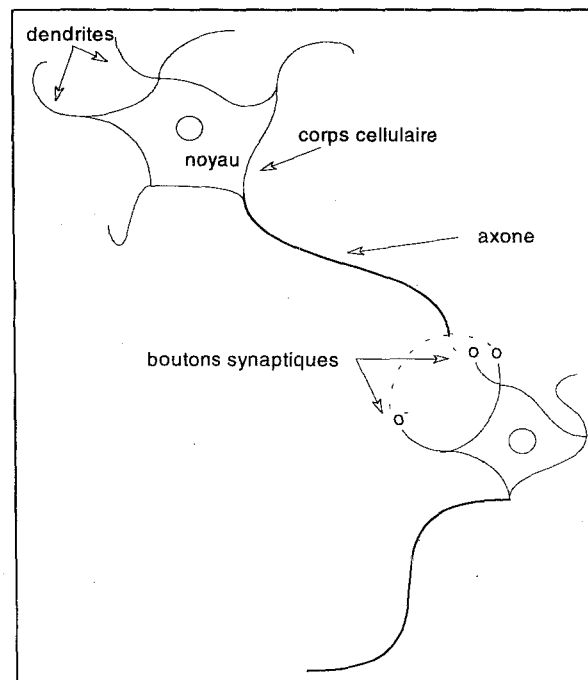


Figure 1 : Schéma simplifié du neurone biologique

Le neurone formel reprend de façon simplifiée le fonctionnement du neurone biologique. Chaque neurone possède plusieurs **entrées**, notées e_i , à partir desquelles il calcule une **sortie** notée S .

Plus concrètement, chaque entrée est pondérée par un **pooids synaptique** noté p_i et une fonction d'activation effectue ensuite la somme pondérée de ces entrées : $\left(\sum_{i=1}^n p_i \cdot e_i \right)$.

Une **fonction de transfert** φ , non linéaire (une fonction sigmoïdale, par exemple), calcule enfin la sortie S en fonction de la valeur de la fonction d'activation, soit :

$$S = \varphi \left(\sum_{i=1}^n p_i \cdot e_i \right)$$

3.2 LES RESEAUX NEURONAUX

Pour former un réseau, les neurones sont connectés les uns aux autres. Une **architecture** classique consiste à disposer les neurones en plusieurs couches successives avec respectivement : une **couche d'entrée**, une ou plusieurs **couches cachées** et une **couche de sortie**. Tous les neurones d'une couche donnée, sauf ceux de la dernière couche, sont ensuite connectés vers chaque neurone de la couche en aval (figure 2).




Figure 2 : Réseau de neurones

Les variables d'entrée du modèle sont présentées aux neurones de la couche d'entrée et les neurones de la couche de sortie vont fournir en conséquence des valeurs.

Les variables d'entrée du modèle sont disposées selon un **vecteur d'entrée** ou **patron d'entrée**. De la même façon, les valeurs de la couche de sortie sont arrangées selon un **vecteur de sortie** ou **patron de sortie**.

3.3 LA FACULTE D'APPRENTISSAGE

La modélisation du phénomène physique par le réseau de neurones passe par une première phase appelée phase d'apprentissage. Dans le cas le plus fréquent, des vecteurs d'entrée sont présentés au réseau qui ajuste la pondération de chaque neurone de manière à rapprocher au mieux les sorties désirées de celles calculées. Concrètement, l'erreur entre la valeur de sortie attendue et celle calculée est répercutée en amont en modifiant la pondération des différents neurones. Cette technique est celle de la rétropropagation. Cet ensemble de vecteurs d'entrée et de sortie, appelé **corpus d'apprentissage**, est présenté un certain nombre de fois au réseau de façon à permettre un ajustement correct de la pondération.

Si le réseau doit montrer de bonnes performances avec le corpus d'apprentissage, il doit aussi répondre correctement lors de la présentation de vecteurs qu'il n'a jamais rencontrés. Pour vérifier cela, de nouveaux vecteurs (**corpus de test ou de validation**) qui n'ont pas servi à l'apprentissage sont ensuite introduits dans le réseau. Une bonne qualité du résultat permet alors de valider un apprentissage correct du réseau.

Le réseau de neurones exprime ici son potentiel de généralisation : à partir de l'échantillon d'une population, il en retire la règle régissant l'ensemble de la population.

3.4 L'EVALUATION DES PERFORMANCES

La performance du réseau peut être évaluée à partir de différents paramètres. Tout d'abord, il est possible d'évaluer l'erreur entre les valeurs désirées et les valeurs calculées par la couche de sortie du réseau de neurones. Pour cela, on calcule le paramètre noté RMS (Root Mean Square) qui additionne les carrés des erreurs pour chaque neurone de la couche de sortie et prend la racine carrée de cette somme divisée par le nombre de neurones de la couche de sortie.

$$\text{RMS} = \sqrt{\frac{\sum_{\text{N neurones}} (X - X^*)^2}{N}}$$

avec :

- X, la valeur désirée normalisée ;
- X*, la valeur estimée normalisée ;
- N, le nombre de neurones de la couche de sortie.

Plus la RMS est faible, meilleure est la performance du réseau.

Par ailleurs, le coefficient de corrélation entre les valeurs désirées et celles estimées, pour chaque neurone de la couche de sortie, constitue un paramètre supplémentaire pour estimer la performance du réseau. Il est calculé selon :

$$\rho = \frac{\sum_n (X - \bar{X})(X^* - \bar{X}^*)}{\sqrt{\sum_n (X - \bar{X})^2 \sum_n (X^* - \bar{X}^*)^2}}$$

avec :

- n, le nombre de vecteurs présentés au réseau ;
- $\bar{X} = \frac{1}{n} \sum_n X$;
- $\bar{X}^* = \frac{1}{n} \sum_n X^*$;

Le coefficient de corrélation, compris entre -1 et 1, traduit une bonne performance du réseau lorsque sa valeur se rapproche de 1.

3.5 LE GENERATEUR DE RESEAUX DE NEURONES

La disponibilité d'outils informatiques de plus en plus puissants permet aujourd'hui de disposer de logiciels relativement conviviaux et de s'affranchir de la programmation des différents algorithmes de calcul du réseau de neurones.

Succinctement, les fonctions de ces logiciels générateurs de réseau de neurones vont :

- de la définition de l'architecture du réseau (nombre de neurones dans la couche d'entrée, dans les couches cachées et dans celle de sortie, par exemple) ;
- au choix des algorithmes d'apprentissage du réseau et de leur paramétrage ;
- jusqu'à l'emploi du réseau en tant qu'outil de modélisation.

En outre, ces logiciels disposent généralement d'interfaces graphiques facilitant la visualisation et l'interprétation des résultats, et d'outils d'analyse statistique des résultats.

4 MODELISATION DES DEGAGEMENTS DE GRISOU

4.1 OBJECTIF

Les travaux présentés concernent les développements du modèle destiné à prévoir la valeur moyenne de la teneur en méthane, sur un poste de 8 heures, situé plus ou moins loin dans le futur.

4.2 METHODOLOGIE

Le développement d'un réseau de neurones repose principalement sur la détermination :

- du **modèle** ;
- d'une **structure neuronale** adaptée au modèle défini, et donc relative à l'architecture du réseau avec concrètement la répartition des neurones, les connexions entre neurones, la fonction de transfert, les poids synaptiques initiaux...

Le mécanisme du dégagement grisouteux fait intervenir de nombreux paramètres tels la stratigraphie autour de la veine exploitée, la concentration en gaz des veines de charbon et des bancs stériles, l'isotherme d'adsorption du CH₄ des veines de charbon, le degré de dégazage des bancs, la nature des roches environnantes, la perméabilité du milieu...

De nombreux travaux de recherche ont par ailleurs montré que, dans un régime établi de dégagement grisouteux, la quantité de grisou dégagé dans un chantier donné est franchement dépendante de sa production [BRUYET, 1967 ; BOROWSKI, 1969 ; KAFFANKE, 1980].

La pratique des réseaux de neurones montre aussi qu'il est préférable d'utiliser les variables caractérisant le phénomène physique étudié sous la forme la plus basique possible.

Le modèle a de ce fait été développé de manière à relier les dégagements de grisou à l'activité du chantier, sur la base des trois variables ci-dessous, soit pour :

- caractériser le dégagement de grisou :
 - la teneur en CH₄ dans le retour d'air [%] ;
 - et le débit d'air dans le circuit de la taille [m³/s] ;
- traduire l'activité de la taille :
 - la distance parcourue par la haveuse dans la taille en phase de coupe [m].

Le réseau de neurones a donc été construit à partir des variables d'entrée et de sortie suivantes, en retenant comme :

- variable de sortie :
 - la teneur moyenne en méthane sur un poste situé plus ou moins loin dans le futur ;
- variables d'entrée :
 - les teneurs moyennes en méthane sur les postes passés ;
 - les débits d'air moyens sur les postes passés et les valeurs prévues sur les postes futurs ;
 - les distances parcourues par la haveuse en phase de coupe sur les postes passés et les valeurs prévues sur les postes futurs.

Les développements consistent ensuite à caractériser ces variables vis-à-vis du phénomène physique des dégagements grisouteux. Les principaux points étudiés et présentés ici reposent sur la détermination de :

- **l'échantillonnage des données.** Les variables peuvent être décrites selon différents pas de temps. Cela va influencer la représentativité des données puisqu'un pas de temps trop long peut masquer certaines caractéristiques du phénomène modélisé, tandis qu'un pas de temps plus court permet de disposer d'une base de données plus riche et plus représentative de l'activité du chantier d'exploitation ;
- **la fenêtre temporelle** permettant la description des variables explicatives dans un passé plus ou moins lointain ;
- **l'horizon de la prévision.** La teneur peut être prévue sur un poste situé plus ou moins loin dans le futur ;
- **la partition des ensembles d'apprentissage et de test.** Le réseau ajuste sa pondération sur la base des valeurs fournies par l'ensemble d'apprentissage puis évalue sa performance sur un ensemble de test. Il faut tout d'abord connaître le nombre de données nécessaires pour un apprentissage efficace du réseau. Par la suite, il s'agit d'appréhender la capacité du réseau à modéliser les variations du mécanisme des dégagements grisouteux avec l'avancement du chantier. Autrement dit, si l'ensemble d'apprentissage correspond aux données d'exploitation d'une certaine situation d'avancement de la taille, il est nécessaire d'évaluer la performance du réseau sur des ensembles de données correspondant à un avancement plus grand du chantier.

Au final, la méthodologie mise en place a débouché sur la définition et l'évaluation de plusieurs configurations, afin d'aboutir au modèle optimal.

4.3 EXPERIMENTATIONS

Les expérimentations destinées à optimiser le modèle sont illustrées par les résultats obtenus sur le cas de la taille Anna Nord 1036/1140 de l'U.E. Reumaux. Il s'agit ici de prévisions a posteriori, c'est-à-dire dans lesquelles on a comparé les valeurs des teneurs en CH₄ calculées par le modèle à celles effectivement mesurées dans le chantier.

Cette taille se situe dans une zone influencée par l'exploitation de la veine Dora sus-jacente d'environ 35 mètres. L'évolution des différentes variables caractéristiques (teneur en CH₄, débit d'air, et production) au cours de l'exploitation du chantier est reprise par la figure 3 relative au pas de temps de 1 heure.

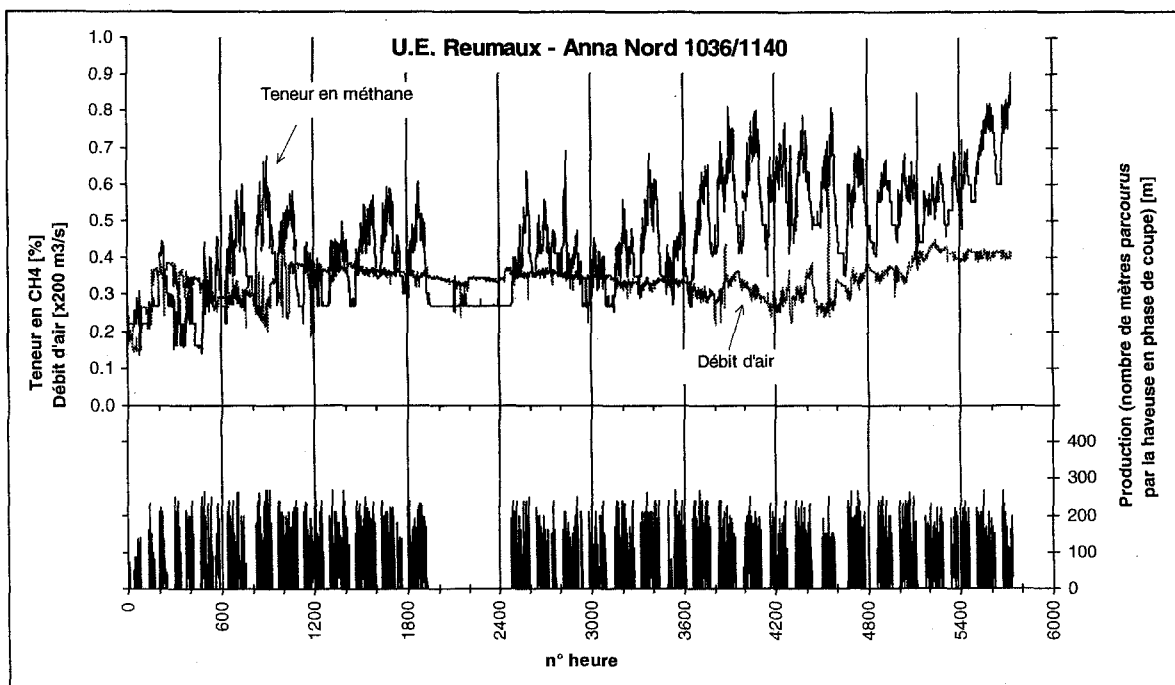


Figure 3 : Evolution des variables caractéristiques de la taille Anna Nord 1036/1140 de l'U.E. Reumaux

4.3.1 Echantillonnage des données

Les expérimentations ont été menées en échantillonnant les données sur différents pas de temps allant de 1 heure à 8 heures. Dans l'ensemble, les résultats s'améliorent lorsque le pas de temps diminue, la valeur minimale est un pas de temps de 1 heure.

Les figures 4 et 5 illustrent d'ailleurs bien cette tendance avec les résultats obtenus sur le cas de la taille Anna. Ces prévisions ont été réalisées sur la même configuration neuronale, exception faite de l'échantillonnage des données effectué pour le premier cas (figure 4) sur un pas de temps de 8 heures et pour le second (figure 5) sur un pas de temps de 1 heure.

Cela est confirmé par l'évaluation des performances avec les valeurs des paramètres suivants :

- la RMS est plus faible pour l'échantillonnage sur un pas de temps de 1 heure (0,025 contre 0,044 sur 8 heures) ;
- le coefficient de corrélation est plus proche de 1 pour l'échantillonnage sur un pas de temps de 1 heure (0,64 contre 0,41 sur 8 heures).

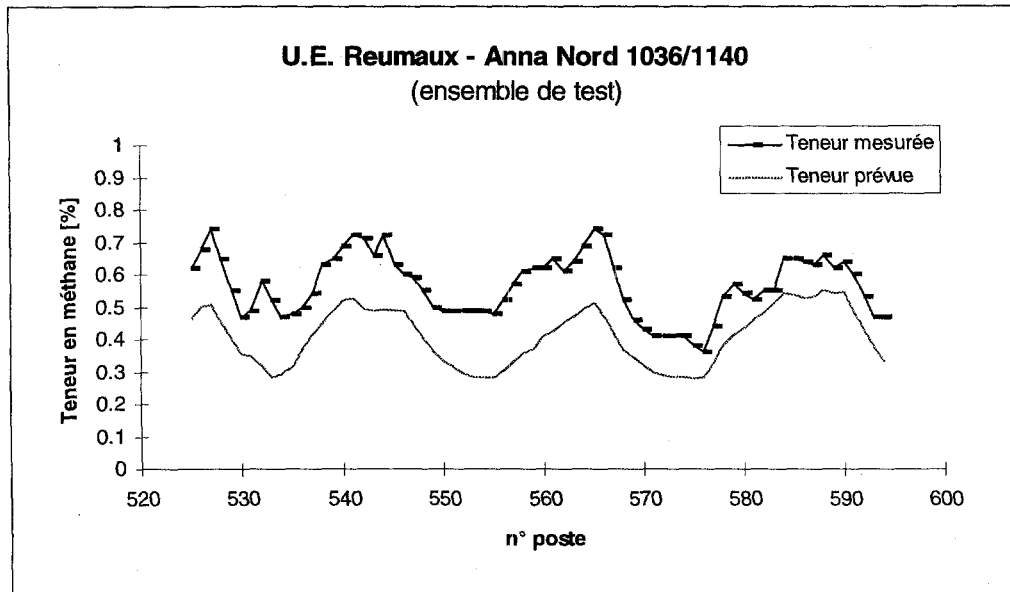


Figure 4 : Prédiction des dégagements de grisou (pas de temps : 8 heures)

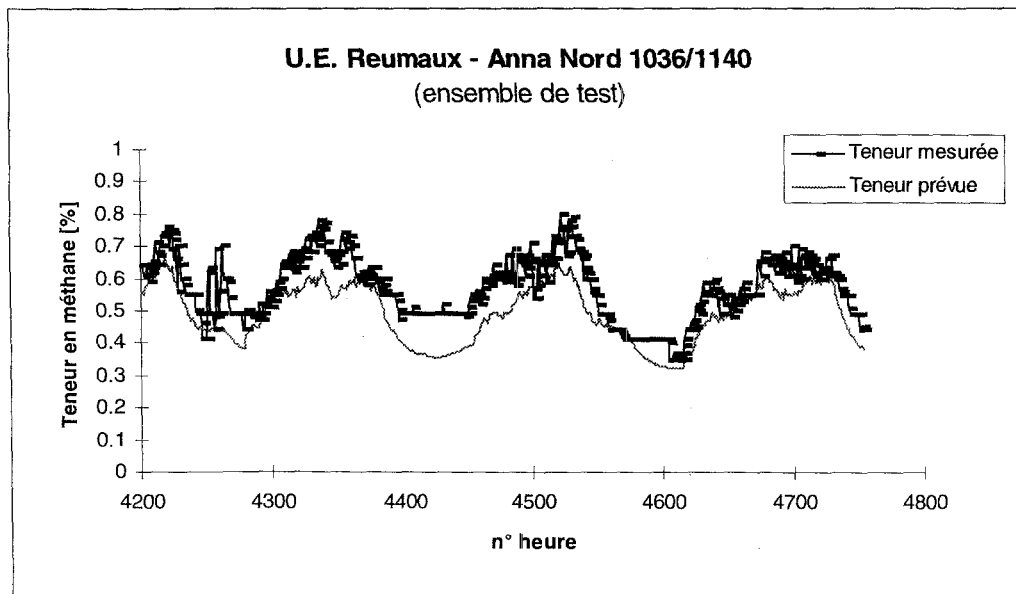


Figure 5 : Prédiction des dégagements de grisou (pas de temps : 1 heure)

4.3.2 Fenêtre temporelle

Les modèles les plus performants sont ceux qui disposent d'un nombre de variables explicatives plus important et apportent de ce fait plus d'informations sur le passé de la taille. Ainsi, de façon logique, les modèles intégrant l'historique de l'activité du chantier, en termes de teneur en méthane dans le retour d'air, de débit d'air en taille et de production, sur une période allant par exemple de l'heure h-15 à l'heure h, donnent de bien meilleurs résultats comparativement aux modèles bâtis avec les variables explicatives décrites uniquement à l'heure h.

Les expérimentations ont toutefois montré que, quel que soit le pas de temps retenu, une fenêtre constituée des données allant de l'heure h-7 à l'heure h semble une configuration minimale pour effectuer une prévision acceptable.

4.3.3 Horizon de la prévision

Les modèles ont été construits pour prévoir la teneur moyenne en méthane, sur un poste de 8 heures, situé plus ou moins loin dans le futur. Des résultats satisfaisants ont été obtenus avec des prévisions concernant au maximum la période située entre l'heure h+25 et h+32.

Lorsque l'horizon est plus éloigné dans le futur, l'ajout de variables explicatives (fenêtre temporelle plus grande) semble moins bénéfique. Ce résultat semble cohérent puisque lorsque la prévision se fait plus loin dans le futur, le passé de la taille a moins d'influence sur le résultat.

4.3.4 Partition des ensembles d'apprentissage et de test

Différentes partitions des ensembles de données d'apprentissage et de données de test ont été sélectionnées :

- d'une part, en translatant les ensembles avec l'avancement de la taille ;
- d'autre part, pour une position donnée de l'ensemble d'apprentissage, en éloignant l'ensemble de test. L'ensemble de test peut soit immédiatement suivre l'ensemble d'apprentissage, soit une, deux ou trois périodes peuvent aussi venir s'intercaler entre l'ensemble de test et l'ensemble d'apprentissage.


Dans tous les cas, les résultats montrent qu'il est préférable de caler le modèle sur la période la plus proche possible de la période de prévision. Lorsque le régime des dégagements grisouteux est relativement stable et identique sur les périodes d'apprentissage et de test, les résultats sont globalement satisfaisants quelle que soit la configuration retenue.

Par contre, lorsque des variations significatives de régime des dégagements grisouteux (développement du volume d'influence, changement du rythme de production...) existent, les prévisions sont moins performantes. Ainsi, des résultats moins bons ont été relevés avec des prévisions concernant le début d'exploitation du chantier, du fait du régime transitoire existant avec le développement progressif du volume d'influence.


Les figures 6 et 7 permettent de comparer des modèles calés sur des ensembles d'apprentissage plus ou moins éloignés de l'ensemble de test. Dans le premier exemple (figure 6), la période de test est éloignée de 600 heures de la période d'apprentissage, tandis que, pour le second, la période de test suit immédiatement la période d'apprentissage. Cette dernière configuration, avec des prévisions réalisées sur le pas de temps du poste, montre de bien meilleurs résultats.

Cela est confirmé par l'évaluation des performances avec les valeurs des paramètres suivants :

- la RMS est alors plus faible pour le second cas (0,008 contre 0,044 pour le premier cas) ;
- et le coefficient de corrélation est plus proche de 1 pour le second cas (0,83 contre 0,41 pour le premier cas).



**Figure 6 : Prédiction des dégagements de grisou
(période de test éloignée de 600 heures de la période d'apprentissage)**




**Figure 7 : Prédiction des dégagements de grisou
(période de test suivant immédiatement la période d'apprentissage)**

4.3.5 Bilan

L'ensemble des expérimentations réalisées mettent clairement en évidence l'importante variabilité des performances suivant la configuration retenue.

D'une manière générale, les modèles les plus performants sont ceux qui disposent d'un nombre de variables explicatives plus important et apportent de ce fait plus d'informations sur le passé de la taille. Ainsi, quel que soit le pas de temps retenu, une fenêtre constituée des données sur la période comprise entre l'heure h-7 et l'heure h semble une configuration minimale pour conduire à une prévision satisfaisante. Parallèlement, dans tous les cas, les résultats sont meilleurs lorsque le modèle est calé sur la période la plus proche possible de la période de prévision.

A titre d'illustration, les résultats présentés à la figure 8 sont issus d'une configuration neuronale regroupant ces deux propriétés.



*Figure 8 : Prédiction des dégagements de grisou
(configuration optimale pour ce régime de dégagement grisouteux)*

5 CONCLUSION

L'application de la technique des réseaux de neurones à la prévision des dégagements de grisou en taille a clairement démontré le potentiel de cette approche.

Plusieurs modèles ont été développés avec pour objectif la prévision des valeurs de la teneur en méthane dans le retour d'air. Ces prévisions sont basées sur les valeurs passées de la teneur en méthane et des valeurs passées et futures des autres variables explicatives du phénomène étudié (débit d'air en taille et production du chantier).

Les expérimentations ont clairement mis en évidence le rôle important de la configuration retenue sur la qualité des résultats. Si des prévisions très satisfaisantes ont pu être réalisées, elles concernent pour le moment des périodes de dégagement grisouteux relativement stable et identique. Les principales difficultés résident en fait dans la modélisation des régimes instables des dégagements grisouteux (développement du volume d'influence, changement du rythme de production...).

Certaines configurations appréhendent toutefois mieux que d'autres ces difficultés. Si la représentativité des données d'apprentissage a toute son importance dans la réussite de la modélisation, les résultats montrent ici que la performance de la prévision est avant toute chose conditionnée par un modèle adéquat du réseau de neurones.

Les développements se poursuivent de ce fait sur l'étude d'expérimentations menées sur le cas de tailles récemment exploitées (Irma Nord 1140/1250 de l'U.E. Reumaux, Albert 3-3-1 et Albert 15-2-1 de l'U.E. La Houve), tant au niveau du modèle de prévision (variables explicatives d'entrée et de sortie, ensembles d'apprentissage...) que de l'architecture du réseau (connexions entre neurones, fonctions de transfert, algorithme d'apprentissage).

6 BIBLIOGRAPHIE

BRUYET, 1967 - « Les variations de teneurs dans les retours d'air de tailles. Influence des facteurs d'exploitation » - Publication CERCHAR n°1815 - Verneuil-en-Halatte, France.

BOROWSKI, 1969 - « Les relations entre la production et le dégagement en taille » - Travaux du GIG, publication n°472 - Katowice, Pologne.

COUILLET J.-C., KOUNIALI S., 1997 - « Faisabilité d'un système de prévision dynamique des dégagements grisouteux par l'approche réseaux de neurones » - Rapport du 13 mars 1997, référencé INERIS-SSE-JCo-SKo/CS-97-25EP33/R03.

COUILLET J.-C., POKRYSZKA Z., 1996 - « Prévision des dégagements de grisou en taille, développement des calculs à partir d'une macro commande Excel » - Journée technique de Charbonnage de France, Saint-Etienne, le 5 juin 1996.

COUILLET J.-C., 1997 - « Prévision dynamique des dégagements de grisou en taille, état actuel des développements » - Rapport de synthèse du 22 avril 1997, référencé INERIS SSE-JCo/JCo-97-25EP33/R05.

DIXON D.W., OZVEREN C.S., SAPULEK A.T., TUCK M.A., 1995 - « The application of neural networks to underground methane prediction » - 7th US Mine Ventilation Symposium, Lexington, Kentucky, USA, 5-8 juin 1995.

JEGER C., 1980 - « Eléments nouveaux dans la prévision du dégagement de grisou dans les tailles » - Journées d'information : grisou, climat et aérage dans les Charbonnages de la Communauté Européenne - Luxembourg.

KAFFANKE, 1980 - « Prévision à moyen terme du dégagement de grisou dans les voies de retour d'air des chantiers » - Journées d'information : grisou, climat et aérage dans les Charbonnages de la Communauté Européenne - Luxembourg.

POKRYSZKA P., TAUZIEDE C., 1994 - « Evolution des méthodes de prévision du dégagement grisouteux » - Journée technique des Charbonnages de France, Hombourg-Haut, le 2 juin 1994.

