

AMELIORATION DE LA PREDICTION DE LA MINERALISATION DE L'AZOTE ORGANIQUE DU SOL *IN SITU* POUR UNE LARGE GAMME DE SOLS FRANCAIS

Matthieu VALÉ^(1,2), François LAURENT⁽³⁾, Luc CHAMPOLIVIER⁽⁴⁾, Bruno MARY⁽⁵⁾ et Eric JUSTES⁽²⁾

¹ SAS depuis le 20/08/07, précédemment CDD ARVALIS et CETIOM basé à INRA – UMR AGIR

² INRA - UMR AGIR (AGrosystèmes et développement territorial) - BP 52627 - 31326 Castanet Tolosan Cedex ; eric.justes@toulouse.inra.fr (auteur correspondant)

³ ARVALIS – Institut du végétal, 91720 Boigneville

⁴ CETIOM - Centre de Grignon - B.P. 4 - 78850 Thiverval-Grignon

⁵ INRA - Unité d'Agronomie Laon-Reims-Mons - Rue Fernand Christ - 02007 LAON CEDEX

I – Contexte et objectifs

Connaître et prévoir précisément la dynamique saisonnière de la minéralisation de l'azote organique du sol *in situ* sont des objectifs difficiles à atteindre en grandes cultures, du fait de la diversité des sols, des systèmes de culture (SdC), des itinéraires techniques (ITK) et des climats, et de la forte hétérogénéité spatiale présente dans un champ cultivé (par exemple Bruchou et Mary, 2007). L'enjeu est de mettre au point des méthodes robustes de prédiction de la minéralisation de l'azote du sol, c'est-à-dire valides pour une large gamme de conditions pédoclimatiques. Ces méthodes doivent être simples à utiliser et les informations nécessaires doivent être faciles d'accès (mesures rapides et peu chères, réalisables en routine).

Les modèles fonctionnels combinant des caractéristiques du sol, du climat et du système de culture semblent être de bons outils de prédiction de la minéralisation de l'azote *in situ*, comme par exemple des modèles sol-plante orientés recherche comme STICS (Brisson *et al.*, 1998), AZODYN (Jeuffroy et Recous, 1999) ou des outils d'aide à la décision comme AZOFERT[®] (Machet *et al.*, 2004). Ces trois modèles ont une filiation forte et sont largement utilisés en France ; ils considèrent que la minéralisation nette d'azote est la somme de la minéralisation de l'humus du sol et la minéralisation des résidus organiques exogènes (résidus de culture et amendements organiques). La prévision de la minéralisation de l'humus au cours du temps est basée sur le concept d'une vitesse potentielle de minéralisation de l'azote spécifique du type de sol (fonction de la teneur en azote organique, en argile et en CaCO₃ de l'horizon de surface), elle-même modulée par les conditions de température et d'humidité du sol, celles-ci étant calculées en fonction des données climatiques. Cette vitesse potentielle de minéralisation de l'azote *in situ* peut être estimée au moyen d'expérimentation en sol nu et du modèle de calcul LIXIM (Mary *et al.*, 1999), nommée ci-après méthode LIXIM.

Un travail de thèse réalisé à l'INRA de Toulouse et financé par ARVALIS Institut du Végétal et le CETIOM, a permis de caractériser, en utilisant la méthode LIXIM, la cinétique de minéralisation d'azote du sol sur un réseau de 55 parcelles de grande culture réparties sur le territoire français (Valé, 2006). Le concept de vitesse potentielle de minéralisation (une vitesse moyenne unique durant toute l'année) a pu être validé sur plus des 2/3 des situations étudiées. Le travail a montré que les modèles de simulation ou outil d'aide à la décision actuellement utilisés en France (AZOFERT, STICS et AZODYN) ne permettent pas de prédire avec une bonne précision cette vitesse potentielle de minéralisation calculée *in situ*. Des modèles statistiques établis par PLS (Partial Least Squares regression) ont permis d'améliorer significativement la prédiction de la minéralisation de l'azote mais au détriment de la simplicité : ils incluent de nombreuses variables dont certaines sont difficiles d'accès comme la biomasse microbienne ou les métabolites microbiens.

Une seconde étape de notre travail a consisté en l'analyse des données au moyen d'une méthode de modélisation statistique basée sur les réseaux de neurones (ANN : Artificial Neuronal Network). C'est une méthode mathématique qui s'inspire du fonctionnement de vrais neurones dont les réseaux sont généralement optimisés par des méthodes "d'apprentissage" (par exemple, Lek et Guégan, 2000). En agronomie, les réseaux de neurones trouvent quelques applications comme pour la prédiction des paramètres de fonctions de pédotransfert (Levine *et al.*, 1996 ; Minasny et McBratney, 2002). Il a ainsi été démontré que la méthode du réseau de neurones était plus efficace que la régression linéaire multiple pour prédire la capacité de rétention en eau d'un sol (Merdun *et al.*, 2006). Il nous semblait donc intéressant d'évaluer l'intérêt de l'ANN pour améliorer les modèles de prédiction de la minéralisation de l'azote organique du sol.

L'objectif de notre travail était de proposer un modèle opérationnel de prédiction de la minéralisation de l'azote organique du sol en conditions réelles (*in situ*). Nous nous sommes également attaché à réaliser une validation indépendante de la qualité prédictive des modèles sélectionnés. Pour cela, une base de données conséquente de situations expérimentales a été constituée pour avoir un jeu de paramétrage d'une part et un jeu de validation d'autre part.

Bien que nous ayons retenu la méthode du réseau de neurones pour modéliser la minéralisation de l'azote, cette démarche statistique a été couplée à une approche fonctionnelle. En effet, le stock d'azote organique du sol est apparu comme étant la première variable explicative de la minéralisation de l'azote (Valé, 2006). Ainsi, au lieu de prédire la vitesse de minéralisation nette d'azote, nous avons cherché à modéliser le taux de minéralisation (appelé K2) qui représente la vitesse de minéralisation par unité d'azote organique.

II – Dispositif expérimental

Une étroite collaboration avec les ingénieurs d'ARVALIS et du CETIOM et les chercheurs de l'INRA a permis la constitution d'un réseau expérimental de 80 parcelles représentant une grande partie des zones de grande culture du territoire français (Figure 1). Ces parcelles couvrent une large gamme de caractéristiques de sol : par exemple, la teneur en argile va de 3 à 40%, le stock d'azote organique sur 0-30 cm varie de 3 à 16 t/ha et la teneur en CaCO₃ est comprise entre 0 et 86%.




Figure 1 : localisation géographique des parcelles d'investigation et variabilité des textures du sol dans la couche de surface

Les différentes étapes de la démarche que nous avons suivie sont les suivantes :

1. Calcul de la minéralisation nette d'azote sur la base des expérimentations en sol nu des 80 parcelles. On fait l'hypothèse que cette minéralisation est attribuable exclusivement à l'humus du sol (et non au précédent cultural) car les résidus de récolte ont été exportés. Le calcul est réalisé selon la méthode LIXIM ;
2. Calcul de la vitesse potentielle de minéralisation (V_p) au moyen du concept de jours normalisés ;
3. Sélection des situations expérimentales au moyen de critères statistiques en gardant les parcelles pour lesquelles V_p est constante et dont l'ajustement mathématique des profils d'eau et d'azote minéral est satisfaisant : 68 parcelles sont retenues, répondant au critère de vitesse unique de minéralisation de l'azote organique (V_p) et d'ajustement étroit et sans biais ;
4. Calcul de la variable K_2 , en supposant que la minéralisation concerne le stock d'azote organique mesuré sur 0-30 cm (pour une question de simplicité de mesure sur le terrain) ;
5. Modélisation au moyen de l'ANN du K_2 sur le jeu de paramétrage en sélectionnant les caractéristiques pédologiques et culturales permettant d'expliquer une part significative de variance. Différents modèles ont été calculés en fonction des variables explicatives retenues (plus ou moins faciles d'accès à la mesure).
6. Validation des variables explicatives significatives et de la qualité prédictive des modèles ANN sélectionnés sur le jeu de validation.
7. Consolidation du paramétrage des modèles ANN sélectionnés en utilisant l'ensemble des 68 parcelles répondant aux critères statistiques dans le but d'avoir le domaine de validité du modèle prédictif le plus large possible (le plus de sols différents possibles). La qualité prédictive est ensuite évaluée par la technique de validation croisée.

La vitesse potentielle de minéralisation de l'azote *in situ* a été estimée par la méthode LIXIM (Mary *et al.*, 1999). Cela consiste par des mesures fréquentes (au minimum mensuelle) du profil d'eau et d'azote minéral (0-120 cm) durant au moins une année sur des parcelles de grande culture, maintenues en sol nu par traitement herbicide (Figure 2).

Le programme de calcul LIXIM utilise ces données ainsi que les données météorologiques afin de calculer simultanément (par optimisation numérique) les valeurs les plus probables de minéralisation nette d'azote et de lixiviation de nitrate *in situ* (Figure 2). L'effet des conditions de température et d'humidité du sol sur la minéralisation nette est ensuite pris en compte de façon indépendante en utilisant le concept de "temps normalisé", qui permet de calculer la vitesse de minéralisation en conditions thermiques et hydriques constantes (Figure 2).

Lorsque la cinétique de minéralisation est linéaire en fonction du temps normalisé, on peut déterminer une pente unique que nous considérons comme la vitesse potentielle de minéralisation de l'azote du sol (V_p), exprimée en $\text{kg N}\cdot\text{ha}^{-1}\cdot\text{jn}^{-1}$ (jn = jours normalisés à 15°C et à l'humidité à la capacité au champ) (Figure 2).

Afin de caractériser la vitesse de minéralisation de l'azote humifié indépendamment de la masse de celui-ci dans les sols, le taux de minéralisation (K_2), qui a été choisi comme variable à expliquer, est estimé par le rapport entre la vitesse potentielle de minéralisation et le stock d'azote organique. Ce ratio est exprimé en kg d'azote minéralisé par tonne d'azote organique mesuré sur 0-30 cm et par jour normalisé (exprimé à 15°C et à l'humidité à la capacité au champ).

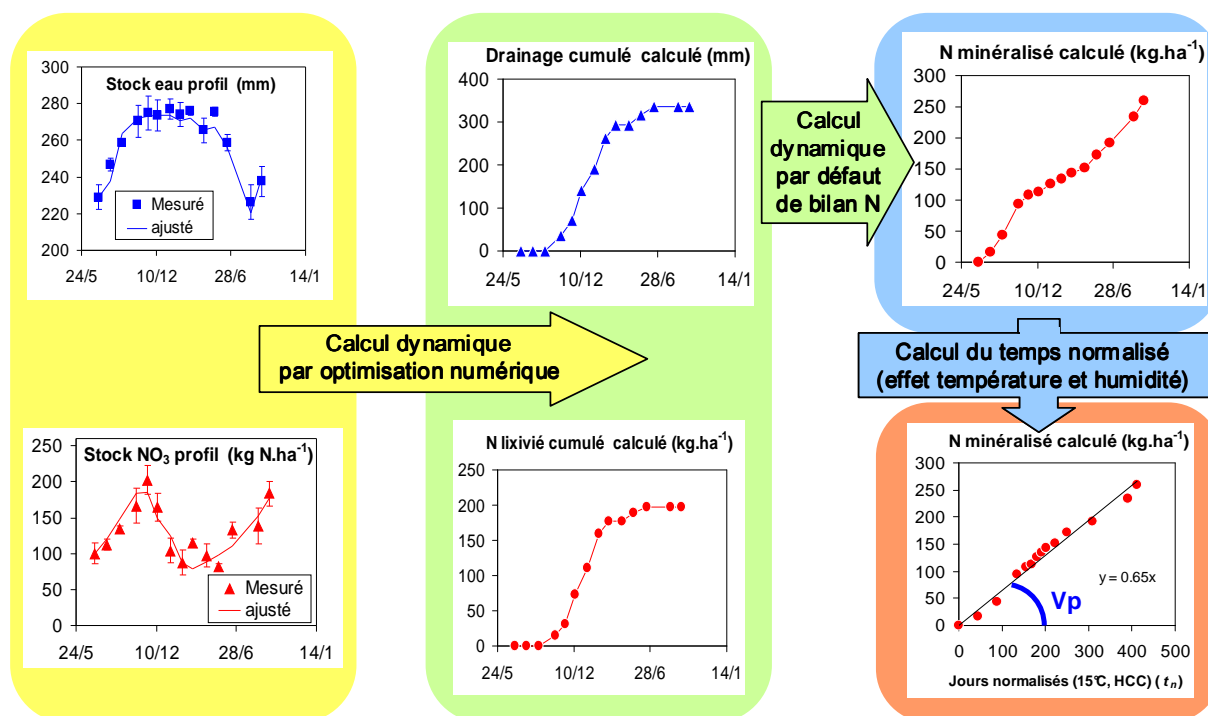


Figure 2 : Les étapes du calcul de la vitesse potentielle de minéralisation de l'azote (V_p) avec la méthode LIXIM

Les variables explicatives de la minéralisation de l'azote regroupent des caractéristiques physico-chimiques, des indicateurs biologiques et des informations sur le système de culture. Les caractéristiques physico-chimiques des sols ont été déterminées au Laboratoire Départemental d'Analyses et de Recherche (LDAR) de Laon sur la couche 0-30 cm. Il s'agit des caractéristiques suivantes : granulométrie 5 fractions après décarbonatation, teneur en CaCO_3 , en azote organique et en P Olsen, pH, CEC cobaltihexamine. La teneur en azote organique de la couche 30-60 cm a également été analysée. Les indicateurs biologiques ont été mesurés à l'INRA de Reims pour la biomasse microbienne par la méthode fumigation – extraction (Vance *et al.*, 1987) et le fractionnement de la matière organique (tamisage sous eau) et au Service d'Etudes en Microbiologie des Sols et de l'Environnement (Université de Bourgogne / INRA de Dijon) pour les « métabolites microbiens » par la méthode autoclavage (Lemaître *et al.*, 1995).

Les informations relatives au système de culture ont été utilisées en calculant la fréquence d'apparition dans la rotation culturale d'un type de culture donnée (céréales à paille, colza, betterave sucrière, légumineuse, maïs ou sorgho, tournesol, autres cultures). Ce calcul a été effectué pour chaque parcelle pour une durée de 5 à 10 ans selon les informations disponibles. Par exemple, si l'occurrence d'une culture est d'une année tous les 4 ans, sa fréquence sera de 0.25.

III – Méthode de modélisation statistique : le réseau de neurones

Le réseau de neurones permet de modéliser des relations non linéaires complexes entre les variables explicatives et la variable à expliquer. Ce réseau est composé de variables réelles ou de construction statistique (appelées neurones), reliées entre elles par des combinaisons de fonctions linéaires et non linéaires (Lek et Guégan, 2000). Il comprend 3 niveaux (Figure 3) :

- les neurones d'entrée, correspondant aux variables explicatives (x) ;
- les neurones de la couche cachée (variables statistiques résultant de la combinaison des neurones d'entrée) ($A1$) à déterminer par l'utilisateur ;
- le neurone de sortie, correspondant à la variable à expliquer ($A2$).

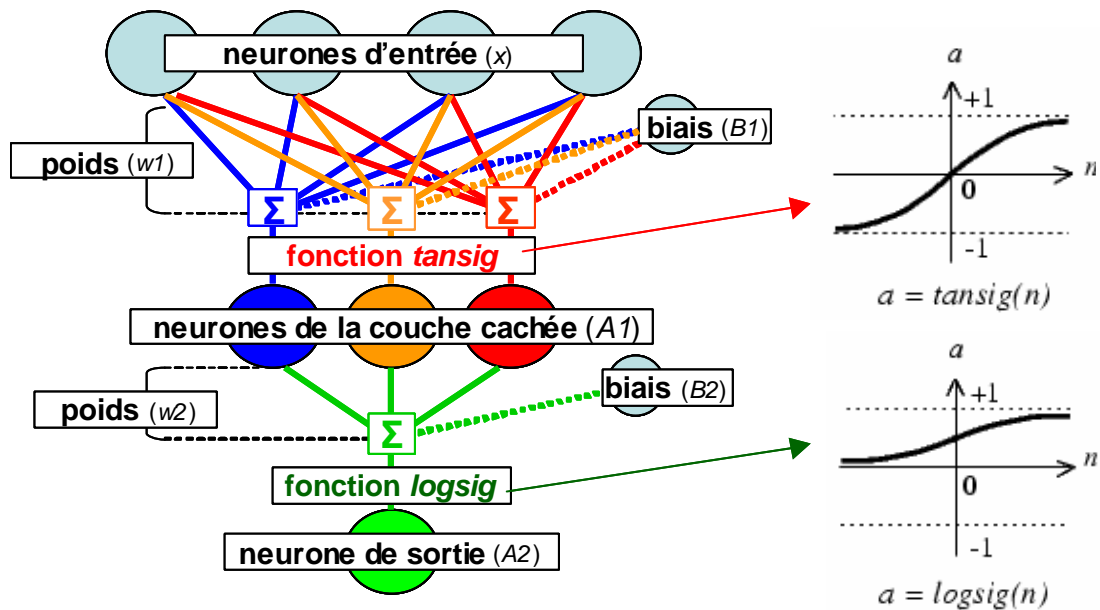


Figure 3 : exemple d'architecture d'un réseau de neurones avec la représentation graphique des fonctions d'activation log sig et tan sig

Le réseau ANN que nous avons utilisé est de type « feed forward » : l'information ne va que dans un seul sens (de l'entrée vers la sortie). Chaque neurone amont se voit attribuer un poids (w) et est combiné linéairement avec les autres neurones de la même couche et un biais (B). A cette somme pondérée est appliquée une fonction d'activation qui permet ainsi de calculer le neurone aval. Nous avons choisi d'utiliser des fonctions sigmoïdes car elles se prêtent bien à la description de phénomènes biologiques. La fonction d'activation entre les neurones d'entrée et les neurones de la couche cachée est de type « tangente sigmoïde » (*tan sig*) et celle entre les neurones de la couche cachée et le neurone de sortie est de type « logistique sigmoïde » (*log sig*) (Figure 3).

L'algorithme d'apprentissage utilisé est de type « back propagation », c'est-à-dire qu'il optimise les paramètres du réseau (poids w et biais B) afin de minimiser l'erreur de prédiction (l'erreur de prédiction est réinjectée au début du réseau). L'erreur calculée est la somme des carrés de écarts entre les K2 prédits et observés. Cet apprentissage se fait par un certain nombre d'itérations, fixé par l'utilisateur et permettant conjointement d'expliquer le plus de variance possible tout en évitant le sur-apprentissage néfaste à la qualité prédictive des modèles ANN.

Les données d'entrée (variables explicatives) sont centrées et réduites, ce qui permet de travailler sur des variables dont les valeurs et les unités sont très différentes sans risque que cela influe sur le poids attribué aux variables du modèle ANN.

Plusieurs tests ont été utilisés pour choisir les paramètres du réseau de neurones afin d'éviter le phénomène de sur-apprentissage (Maren *et al.*, 1990 ; Lek et Guégan, 2000). Ainsi les paramètres retenus sont les suivants : 5 variables d'entrée, 3 neurones dans la couche cachée et une phase d'apprentissage sur 500 itérations.

Le choix des variables a été effectué selon une approche proposée par Gevrey *et al* (2003) qui permet d'évaluer la contribution de chaque variable dans le modèle. Différentes combinaisons des variables les plus contributrices ont ainsi été testées afin d'obtenir le meilleur modèle prédictif.

La qualité prédictive des modèles obtenus a été évaluée à l'aide de plusieurs critères statistiques en plus du R^2 (Smith *et al.*, 1996) :

- La RRMSEP (Relative Root Mean Square Error of Prediction)

$$RRMSEP = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}}{\bar{Y}_i}$$

- l'efficience du modèle, et le biais

$$EF = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2}$$

$$bi\text{ais} = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)$$

n étant le nombre de dates de mesures

Y_i , \hat{Y}_i et \bar{Y}_i étant respectivement les valeurs observées, prédites et la moyenne des valeurs observées du taux de minéralisation (K2).

La phase de modélisation à l'aide du réseau de neurones a été réalisée sous l'environnement MatLab (Mathworks). La base de données a été scindée en 2 parties, l'une pour le paramétrage et l'autre pour la validation des modèles testés. Les 2 bases ont été constituées de telle sorte que la gamme de valeurs des caractéristiques de sol soit équivalente entre le jeu de paramétrage et celui de validation. Cependant, 7 parcelles issues d'une étude sur le site de Kerlavic (22) n'étaient pas comparables aux autres parcelles « grandes cultures » du réseau car les suivis avaient été réalisés après un retournement de prairie ; seuls les mesures au-delà de 18 mois ont été retenues pour estimer la minéralisation du sol. Ces parcelles ont donc été utilisées dans le jeu de validation mais seulement à titre indicatif pour ces types de sol très riches en matière organique ($\approx 6\%$). Ainsi les jeux de paramétrage et de validation comptent respectivement 30 et 38 parcelles.

IV – Résultats : meilleurs modèles obtenus par réseau de neurones

Dans un premier temps, nous avons paramétré un réseau de neurones utilisant les mêmes variables que le formalisme du K2 utilisé dans les modèles STICS et AZOFERT. Dans ces modèles, le taux potentiel de minéralisation de l'azote organique du sol (K_2 , $\text{kg N t Norg}^{-1} \text{ jour}^{-1}$) est prédit à partir d'une fraction active de l'azote organique et des teneurs en argile et en CaCO_3 du sol :

$$K_2 = F_{ACT} * K_2 \text{ pot}$$

avec
$$K_2 \text{ pot} = \frac{65}{(110 + Arg)(600 + CaCO_3)}$$

$K_2 \text{ pot}$ étant la constante de vitesse de minéralisation (jour^{-1})

F_{ACT} étant la proportion d'azote organique actif, fixée à 35%

Arg étant la teneur en argile du sol (g.kg^{-1})

CaCO_3 étant la teneur en calcaire du sol (g.kg^{-1}).

Le formalisme du K2 utilisé notamment dans le modèle de culture STICS n'a pas permis une prédiction satisfaisante du potentiel de minéralisation : l'erreur de prédiction représente 62 % de la moyenne des observés et il y a un biais significatif. De plus le R^2 et l'efficience sont très faibles ($R^2 = 0.04$ et $EF = -0.67$). Ce formalisme est particulièrement en défaut sur les sols riches en MO (parcelles de Sabres et Kerlavic) et les sols calcaires (Figure 4-1). Ces résultats seront utilisés par la suite comme référence actuelle et donc en comparaison de notre travail pour mesurer l'amélioration (ou la dégradation) de la prédiction en utilisant la méthode ANN.

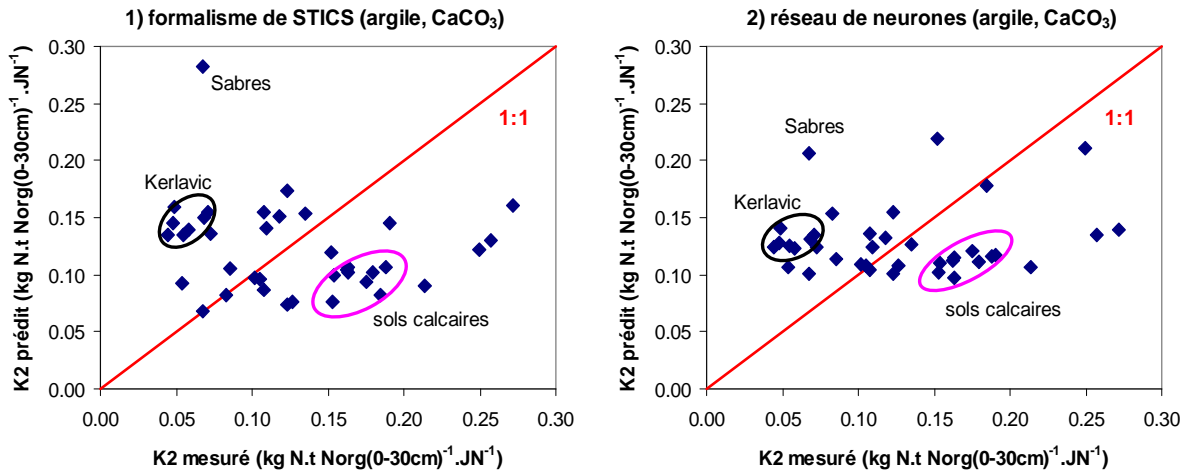


Figure 4 : taux de minéralisation K2 observé et prédit à l'aide du K2 de STICS (1) et du modèle obtenu par ANN avec les variables argile et CaCO₃ (2) pour le jeu de validation

L'erreur de prédiction du réseau de neurones utilisant les mêmes variables que celles du formalisme de STICS (Argile et CaCO₃) a été légèrement réduite mais reste élevée (50 %). Le R² et l'efficacité restent trop faibles (R² = 0.02 et EF = -0.11) et le problème des sols riches en MO et calcaires n'a pas été complètement résolu (Figure 4-2). Ainsi, l'emploi des seules variables Argile et CaCO₃ n'ont pas permis d'obtenir une bonne prédiction de la minéralisation, que ce soit par l'équation paramétrée dans STICS (et donc dans AZODYN et AZOFERT) ou par l'ANN.

Nous avons pu améliorer très fortement la capacité de prédiction du modèle réseau de neurones en ajoutant deux autres variables explicatives. Le meilleur modèle comporte 4 variables simples : argile, CaCO₃, pH et la fréquence de colza dans la rotation (Figure 5). Le paramétrage est très satisfaisant (R² = 0.80 et erreur de 16%) et bien meilleur que celui du modèle n'utilisant que l'argile et le CaCO₃ (R² = 0.51 et erreur de 25%, résultats non présentés). De plus, il permet une réduction de moitié de l'erreur de prédiction par rapport au formalisme actuel de STICS (33% au lieu de 62%). Enfin il ne présente pas de biais pour les sols calcaires et sableux et possède les meilleurs R² et efficacité de prédiction (R² = 0.52 et EF = 0.52). La minéralisation des parcelles calcaires et de celles riches en MO est bien mieux prédite, excepté pour la parcelle de Sabres où la minéralisation reste surestimée mais dans une moindre mesure que précédemment (Figure 5).

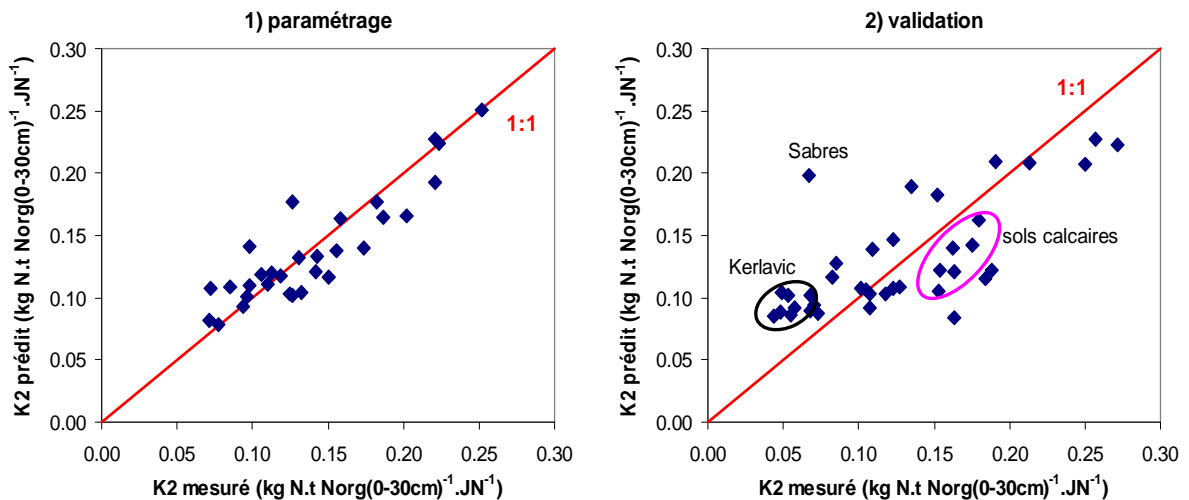


Figure 5 : taux de minéralisation K2 observé et prédit à l'aide du modèle obtenu par réseau de neurones avec les variables argile, CaCO₃, pH et fréquence de colza dans la rotation pour le jeu de paramétrage (1) et de validation (2)

Les modèles utilisant des indicateurs biologiques comme variables d'entrée présentent une amélioration par rapport au formalisme du K2 de STICS mais restent moins performants que le modèle présenté ci-dessus (résultats non présentés). Les 2 indicateurs les plus pertinents sont le rapport C/N de la fraction de MO inférieure à 50 μm et l'azote labile (métabolites microbiens) extrait par autoclavage. L'acquisition d'indicateurs biologiques ne semble donc pas indispensable à une bonne prédiction de la minéralisation de l'azote, d'un point de vue opérationnel. Cependant l'utilisation de ces indicateurs pourrait aider à l'amélioration de la conception des modèles fonctionnels et/ou de recherche.

V – Discussion

Le meilleur modèle proposé remplit à la fois les objectifs de simplicité et de robustesse : il ne nécessite que des variables faciles d'accès et est valide pour une large gamme de conditions pédoclimatiques. Cependant, une des limites de ce modèle obtenu par réseau de neurones est sa complexité : il n'y a pas de relation simple entre les variables explicatives et le K2, ce qui rend difficile l'interprétation de l'effet de ces variables. Nous avons donc utilisé ces 4 variables (A, CaCO_3 , pH, fréquence de colza dans la rotation) pour paramétrer un modèle avec une autre méthode de modélisation statistique : la PLS (Partial Least Squares regression). Les effets des variables explicatives sont plus simples à interpréter car il n'y a que des relations linéaires simples entre les prédicteurs et la variable à expliquer. Cependant, le modèle obtenu par PLS avec les 4 variables les plus contributrices reste nettement moins performant que celui obtenu par réseau de neurones : l'erreur de prédiction passe de 33% à 49% (ces performances sont comparables au modèle par ANN n'utilisant que l'argile et le CaCO_3). La méthode du réseau de neurones est donc bien plus performante, sans doute grâce aux relations non linéaires et complexes entre les variables. Il reste néanmoins à analyser plus en détails la signification fonctionnelles de ces relations statistiques complexes.

Le meilleur modèle utilise la fréquence de colza dans la rotation. Ce résultat est étonnant car seulement un quart des parcelles de notre base de données ont du colza dans leur rotation. Pourtant si cette variable est supprimée ou remplacée par une autre, l'erreur de prédiction peut être augmentée de 10 à 20% (passage de 20 à 30 ou 40% d'erreur). L'importance de cette variable est donc indéniable mais difficile à expliquer avec les connaissances actuelles. L'effet positif du colza sur la minéralisation de l'azote pourrait s'expliquer par la masse importante de biomasse verte qui tombe au sol en cours de culture avec une teneur en azote élevée et une vitesse de minéralisation rapide. La masse d'azote ainsi restituée au sol peut représenter 50 à 100 kg N ha^{-1} (Justes *et al.*, 2000). La majeure partie de cet azote organique s'incorpore à la matière organique du sol et favoriserait la minéralisation ultérieure de l'azote organique du sol.

Cependant cette hypothèse suggère que la minéralisation de l'azote devrait être consécutive à la culture de colza et ne devrait pas perdurer sur plusieurs années. Or dans notre cas, l'effet est positif quelle que soit l'antériorité du précédent colza dans la rotation. Ainsi, une autre hypothèse pourrait concerner la structure des communautés microbiennes du sol. Certaines propriétés de biofumigation ont été attribuées aux crucifères (Kirkegaard et Sarwar, 1998 ; Laegdsmand *et al.*, 2007), sans doute en rapport avec la présence de glucosinolates dans leurs tissus. Ces composés sont hydrolysés à l'intérieur des tissus des crucifères en isothiocyanates qui ont des propriétés biocides. Ainsi l'utilisation des crucifères comme engrais verts a été proposée pour limiter le développement des micro-organismes pathogènes du sol. La culture de colza restituant une grande quantité de résidus au sol tout au long de son cycle, l'effet biocide pourrait affecter la biomasse microbienne et favoriser la minéralisation de l'azote.

L'utilisation de la variable « fréquence de colza dans la rotation » améliore la qualité de prédiction de la minéralisation à la fois dans les parcelles ayant eu du colza et dans les parcelles sans colza. Le réseau de neurones étant un modèle purement statistique, il se peut

que cette variable permette de compenser une erreur de prédiction due aux autres variables. Il reste donc à démontrer la signification fonctionnelle de cette variable. Cela ouvre une piste de recherche intéressante à creuser car l'effet « colza » avait également été clairement mis en évidence en utilisant la méthode PLS avec laquelle nous avons déjà montré qu'il contribuait le plus à l'explication de la variance de K2 (Valé, 2006).

VI – Conclusion

La méthode du réseau de neurones (ANN) a permis d'obtenir des modèles améliorant significativement la prédiction de la minéralisation de l'azote par rapport au formalisme existant prenant en compte seulement l'argile et le CaCO_3 . **Le meilleur modèle comporte 4 variables : la teneur en argile, en CaCO_3 et le pH de la couche 0-30 cm ainsi que la fréquence de colza dans la rotation culturale.** Ce modèle remplit les conditions nécessaires à l'obtention d'un modèle opérationnel : il est **robuste dans la large gamme** de conditions pédoclimatiques explorées et **ses variables sont faciles d'accès**. Il pourra donc être utilisé dans des applications pratiques comme dans les outils d'aide à la fertilisation.

Il faut cependant garder à l'esprit que c'est un modèle statistique, ce qui impose 2 principales limites :

- 1) Son domaine de validité correspond à la gamme de conditions pédoclimatiques incluses dans la base de paramétrage. Nous l'avons conçue aussi large que possible mais toutes les situations françaises n'ont pu être explorées. Ainsi, il ne devra pas être utilisé sans vérification préalable dans des sols ayant une teneur en argile supérieure à 40%.
- 2) Cette approche statistique n'a pas de signification fonctionnelle stricte. Les relations entre les prédicteurs et la variable à expliquer sont nombreuses et complexes à l'intérieur du réseau de neurones : il n'y pas d'effet simple et unique d'une variable sur la minéralisation de l'azote, mais c'est l'ensemble des interactions simulées qui font l'intérêt de cette méthode ANN.

Ce travail a nécessité l'acquisition de nombreuses références de minéralisation de l'azote organique *in situ* dans une large gamme de pédoclimats et de systèmes de grande culture ; c'est un travail fastidieux et très consommateur de temps et de coûts d'analyse. Cependant, nous montrés que cette étude a permis de proposer des voies d'amélioration significatives de la prédiction de la minéralisation de l'azote dans les sols français. Les modèles de prédiction de la minéralisation de l'azote *in situ* proposés pourront être utilisés dans des modèles « de recherche » ou des outils d'aide à la décision, en fonction des variables sélectionnées. Ils pourraient ainsi contribuer à l'amélioration de la gestion de la fertilisation azotée en grande culture, par une meilleure prévision de la fourniture d'azote minéral par le sol provenant de la minéralisation de l'azote organique « humifié ».

Références bibliographiques

- Brisson N, Mary B, Ripoche D, Jeuffroy MH, Ruget F, Nicoullaud B, Gate P, Devienne-Barret F, Antonioletti R, Durr C, Richard G, Beaudoin N, Recous S, Tayot X, Plenet D, Cellier P, Machel JM, Meynard JM et Delecolle R (1998) STICS: a generic model for the simulation of crops and their water and nitrogen balances. I. Theory and parameterization applied to wheat and corn. *Agronomie* 18: 311-346
- Bruchou C et Mary B (2007) Analyse statistique de caractéristiques permanentes et non permanentes du sol d'une parcelle agricole. In "*Agriculture de précision*", M. Guérif et D. King eds., Editions QUAE, INRA Versailles, 147-164.

- Gevrey M, Dimopoulos L et Lek S (2003) Review and comparison of methods to study the contribution of variables in artificial neural network models. *Ecological Modelling* 160: 249-264
- Jeuffroy M-H et Recous S (1999) Azodyn: a simple model simulating the date of nitrogen deficiency for decision support in wheat fertilization. *European Journal of Agronomy* 10: 129-144
- Justes E, Denoroy P, Gabrielle B, Gosse G (2000) Effect of crop nitrogen status and temperature on the radiation use efficiency of winter oilseed rape. *European Journal of Agronomy* 13: 165-177
- Kirkegaard JA et Sarwar M (1998) Biofumigation potential of brassicas - I. Variation in glucosinolate profiles of diverse field-grown brassicas. *Plant Soil* 201: 71-89
- Laegdsmand M, Gimsing A, Strobel B, Sorensen J, Jacobsen O et Hansen H (2007) Leaching of isothiocyanates through intact soil following simulated biofumigation. *Plant Soil* 291: 81-92
- Lek S et Guegan JF (2000) Artificial Neuronal Networks : Application to Ecology and Evolution. In: Lek S and Guegan JF (eds) Springer-Verlag, Berlin, pp 1-262
- Lemaitre A, Chaussod R, Tavant Y et Bruckert S (1995) An attempt to determine a pool of labile organic matter associated with the soil microbial biomass. *European Journal of Soil Biology* 31: 121-125
- Levine E et Kimes D (1998) Predicting soil carbon in Mollisols using neural networks. In *Soil processes and the carbon cycle*. CRC Press Inc, pp 473-484
- Machet J, Recous S, Jeuffroy M, Mary B, Nicolardot B et Parnaudeau V (2004) A dynamic version of the predictive balance sheet method for fertiliser N advice. *Controlling nitrogen flows and losses 12th Nitrogen Workshop*, University of Exeter, UK, 21-24 September 2003 191-193
- Maren A, Harston C et Pap R (1990) Handbook of neural computing applications. Academic Press, San Diego, pp -448
- Mary B, Beaudoin N, Justes E et Machet J (1999) Calculation of nitrogen mineralization and leaching in fallow soil using a simple dynamic model. *Eur J Soil Science* 50: 549-566
- Merdun H, Cinar O, Meral R et Apan M (2006) Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil and Tillage Research* 90: 108-116
- Minasny B et Mcbratney AB (2002) The neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Sci Soc Am J* 66: 352-361
- Nicolardot B, Recous S et Mary B (2001) Simulation of C and N mineralisation during crop residue decomposition: a simple dynamic model based on the C:N ratio of the residues. *Plant Soil* 228: 83-103
- Smith J, Smith P et Addiscott TM (1996) Quantitative methods to evaluate and compare Soil Organic Matter (SOM) Models. In: Powlson D, Smith P, and Smith J (eds) *Evaluation of Soil Organic Matter Models*. Springer-Verlag, Berlin, pp 181-199
- Valé M (2006) Quantification et prédiction de la minéralisation nette de l'azote du sol *in situ*, sous divers pédoclimats et systèmes de culture français. Thèse, INPT-ENSAT, 183 pp + annexes (lien internet : <http://ethesis.inp-toulouse.fr/archive/00000301/>)
- Vance E, Brookes P et Jenkinson D (1987) An extraction method for measuring soil microbial biomass C. *Soil Biology & Biochemistry* 19: 703-707