



HAL
open science

La qualité des données

Line Boulonne, Bertrand Laroche, Céline Ratié, Nicolas N. Saby

► **To cite this version:**

Line Boulonne, Bertrand Laroche, Céline Ratié, Nicolas N. Saby. La qualité des données. Séminaire du Département Environnement et Agronomie "Les Bases de données SOL", Sep 2014, Orléans, France. 11 p. hal-02801156

HAL Id: hal-02801156

<https://hal.inrae.fr/hal-02801156>

Submitted on 5 Jun 2020

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.



La qualité des données

Line Boulonne, Bertrand Laroche, Céline Ratié, Nicolas Saby



NOM DE L'AUTEUR

JOUR / MOIS / ANNEE

La qualité des données

Les missions du GIS Sol sont :

d'améliorer la connaissance et la surveillance des sols de France
et de capitaliser les analyses de sols

La capitalisation de données sur les sols ne doit pas se faire au détriment de leur qualité

➔ mise en place d'un certain nombre d'étapes ou de stratégie pour s'assurer de la qualité des données stockées dans la base de données

Avec plusieurs objectifs :

- Mettre à disposition une donnée de qualité
- Les utilisateurs disposent d'une information sur le contexte d'acquisition et d'intégration au SI.
- Crédibilité des données fournies

Les contrôles sont effectués :

- A toutes les étapes; de l'acquisition à l'intégration des informations au SI,
- Ces étapes sont différentes suivant le programme dans lequel les données ont été acquises.

Contrôle dans la collecte des données

IGCS	RMQS
Rédaction de documents (cahiers des charges, documents qualités, protocoles, documents explicatifs ...)	
Choix des partenaires (compétences, crédibilité locale ...)	
Aide au montage du programme (calendrier, objectifs, ..)	Mise en place de conventions
Formation des partenaires (formation à l'utilisation de DoneSol) http://www.gissol.fr/actualite/formation.php	
	Formation sur le terrain (Protocole RMQS (échantillonnage, observations)
Suivis techniques (comités de pilotage, échanges réguliers, ...)	Un contrôle du travail de l'équipe locale sur site par un opérateur d'InfoSol, effectué tous les 5 à 10 sites

Collecte des données : les données analytiques

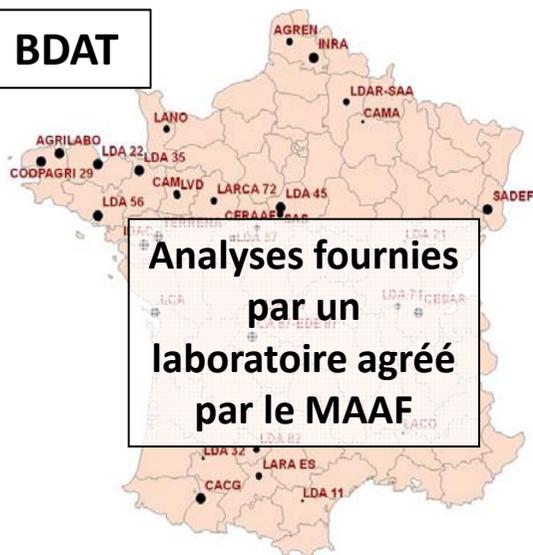
RMQS

Un seul laboratoire : LAS (Laboratoire d'Analyses des Sols (LAS) : laboratoire central pour les analyses de sol de l'INRA)

IGCS

Chaque région collabore avec son laboratoire (appel d'offre, ..) -> seule contrainte laboratoire agréé

BDAT



Validation et expertise des données

- Harmonisation des formats de stockages
- Harmonisation des unités
- Vérification des méthodes de mesure
- Présence de doublons
- Absence/présence des données
- Identification correcte d'une commune

Intégration dans la BDAT



Les laboratoires effectuent des tests de cohérences sur les résultats d'un même échantillon
 $3,5 < \text{pH eau} < 9$ ou encore $\text{CaCO}_3 \text{ total} < 1,5 \text{ g/kg}$ si $\text{pH eau} < 6,5$

BDAT RMQS IGCS

Qualité des résultats analytiques (tous programmes)

Les laboratoires agréés

Dans le cahier des charges, les analyses des échantillons doivent être faites par des laboratoires agréés.

Un laboratoire est agréé par le Ministère de l'Agriculture :

- sous la condition d'utiliser des méthodes normalisées
- de se soumettre à un circuit de contrôle national

-> Ceci garantit de pouvoir comparer les résultats d'un laboratoire à l'autre.

La liste des laboratoires agréés est disponible via les liens suivants :

<http://www.legifrance.gouv.fr/affichTexte.do?cidTexte=JORFTEXT000028316901&dateTexte&categorieLien=id>

<http://www.gemas.asso.fr/?accueil=laboratoires> (site du GEMAS : Groupement d'Etudes Méthodologiques pour l'Analyse des Sols)

Chaque laboratoire fournit une incertitude sur les analyses -> prise en compte dans les calculs

Aldana Jague, E. (2011). *Estimation des sources de variabilité du stock de carbone dans les sols du RMQS.*

(Rapport de stage, Université de Tours).

Martin, M., Boulonne, L., Saby, N., Jolivet, C., Arrouays, D., Aldana Jague, E. (2012).

Estimating Sources Of Uncertainties Of Soil Organic Carbon Stock Assessments Within A Soil Monitoring Network.

Presented at 4th International Congress of the European Soil Science Societies Eurosoil 2012, Bari, ITA (2012-07-02 - 2012-07-06).

BOUKIR, H. (2012). *Estimation des sources d'erreurs sur la mesure des teneurs en contaminants dans les sols*

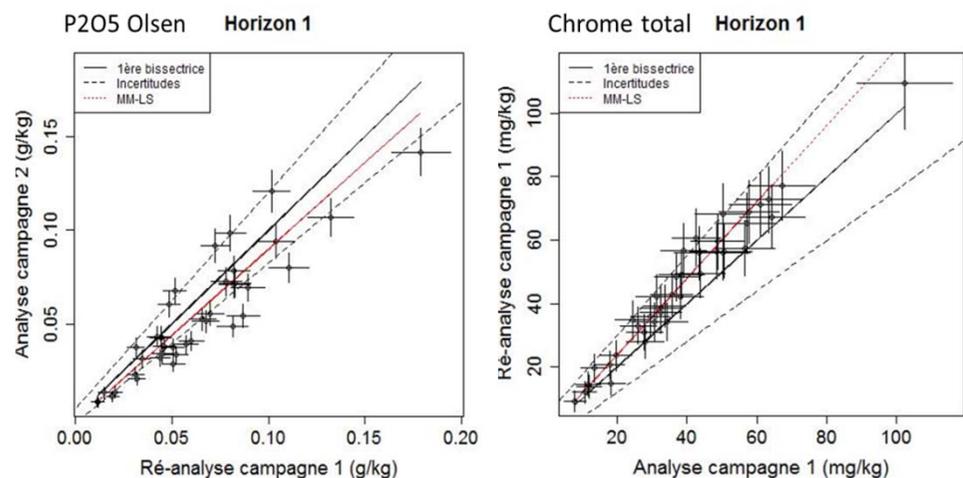
du Réseau de Mesure de Qualité des Sols par analyse de variance hiérarchique (Rapport de stage, Université d'Orléans).

Qualité des résultats analytiques

Evolution des données analytiques avec le temps

RMQS

- Des travaux sont conduits avant d'identifier s'il y a une variation significative ou l'absence de variation des propriétés du sol dans le temps -> campagne test en région Centre 2001/2004 - 2010



La détection d'une variation temporelle est indissociable de la prise en compte de l'incertitude analytique (voir ici l'exemple du P205 Olsen)

un biais systématique a été détecté sur le Chrome, lié à un léger changement dans la méthode non signalé par le LAS

Boulonne, L., et al (2014). Enseignements tirés de la comparaison des résultats analytiques entre deux campagnes du RMQS, en Région Centre. In: *12. Journées d'Etude des Sols : Le sol en héritage*. Présenté aux 12^{ème}. Journées d'Etudes des Sols, Le Bourget du Lac, FRA (2014-06-30 - 2014-07-04).

BDAT

Les méthodes d'analyse sont normalisées par l'AFNOR et garantissent la répétabilité des mesures. Ainsi les résultats obtenus à cinq ans de distance sont comparables dans la même parcelle à condition d'utiliser la même méthode d'analyse.

Contrôle des données saisies

IGCS	RMQS
Rédaction de documents (cahiers des charges, documents qualités, protocoles, documents explicatifs ...)	
Choix des partenaires (compétences, crédibilité locale ...)	
Aide au montage du programme (calendrier, objectifs, ..)	Mise en place de conventions
Formation des partenaires (formation à l'utilisation de DoneSol) http://www.gissol.fr/actualite/formation.php	
	Formation sur le terrain (Protocole RMQS (échantillonnage, observations)
Suivis techniques (comités de pilotage, échanges réguliers, ...)	Un contrôle du travail de l'équipe locale sur site par un opérateur d'InfoSol, effectué tous les 5 à 10 sites
Vérification des couches graphiques (topographie,)	Contrôle manuel du rapport d'échantillonnage de site afin de corriger des dérives éventuelles.
	Contrôle manuel de données hors Donesol (environnement végétation, pratiques, ...)
DonesolWeb : contrôle à la saisie des données	
Vérifications sémantiques des données (manuellement et à l'aide de sivercoh)	
Corrections par les partenaires IGCS	Corrections InfoSol

Qualité des données saisies

Des contrôles manuels

Des tests supplémentaires en tenant compte d'autres variables ou entre plusieurs échantillons d'un même profil

Exemple : taux de carbone de la couche de surface est supérieur au taux de carbone de la couche de sous-surface

Des contrôles à l'interface, toutes les données saisies via DonesolWeb (RMQS, IGCS)

Avec des contrôles sur l'interface de saisie :

- sur la typologie des données rentrées : numérique ou non

- sur l'amplitude des valeurs pour certaines données

 - (ex pH, les valeurs doivent être comprises entre 1 et 14)

- Sur la dépendance de champs par rapport aux autres

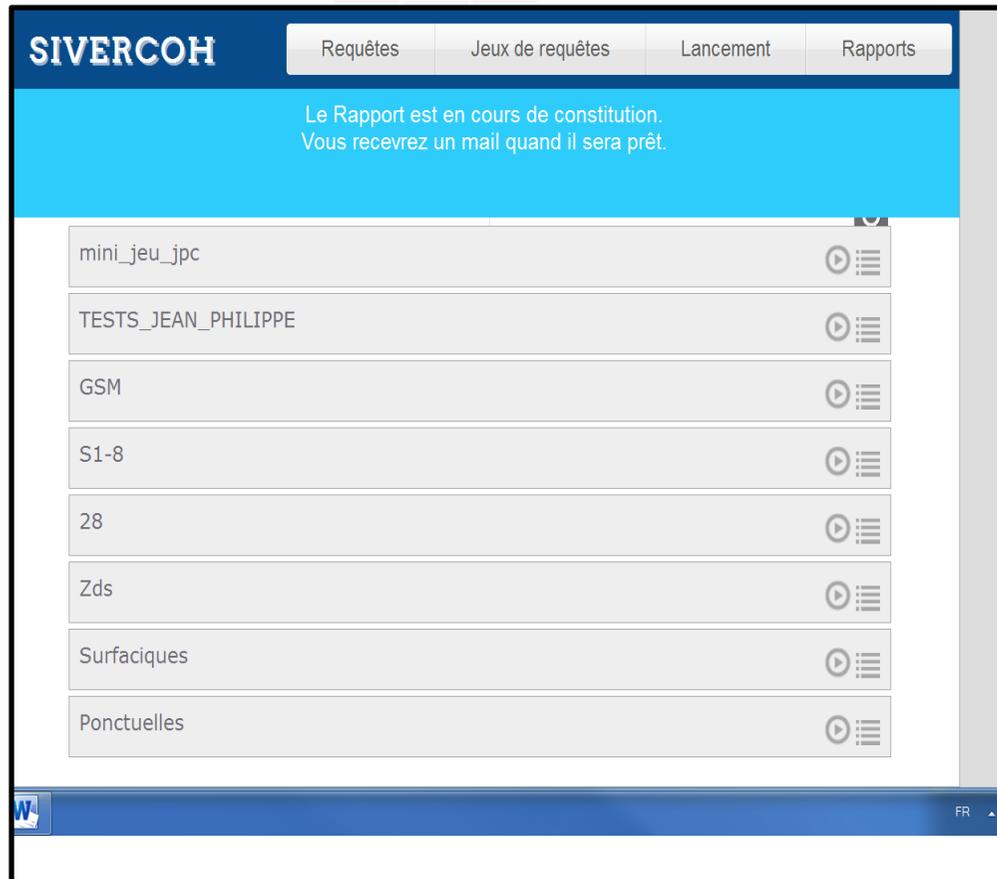
 - (ex une taille d'éléments grossiers ne peut être renseignée si l'abondance de ces éléments est de 0%)

Le traitement des données permet aussi d'identifier des anomalies à posteriori.

-> report des anomalies dans un outil central (bugzilla) pour corrections

Qualité des données saisies

SIVERCOH : un outil de vérification de la cohérence des données



Lancement de jeux de requêtes

Cohérence des données

par rapport CCTG

au sein d'une même table

si il y a un excès d'eau -> les champs
concernant l'hydromorphie doivent être
renseignés

Entre les tables

par rapport à la classification
choisie

Qualité des données saisies

SIVERCOH : un outil de vérification de la cohérence des données

Rapport n°211 25/08/2014 - 11:01:26							
exécution du jeu Surfaiques composé de 178 requête(s)							
par LAROCHE Bertrand - bertrand.laroche@orleans.inra.fr							
avec les paramètres : no_etude = 32360							
47 requête(s) en anomalie 434 ligne(s) anomalique(s)							
n° Anomalie	id_ucs	no_ucs	id_uts	no_uts	id_strate	no_strate	Anomalie
1300379	16008	3108					Le nombre d'UTS annoncé dans UCS est # du nombre d'enregistrements dans L_UCS_UTS pour cette même UCS
1300661			22040				PROF_APPAR_MIN, MOY OU MAX de la strate 2 ne correspond pas a EPAIS_MIN, MOY ou MAX de la strate 1
1300662			22052				PROF_APPAR_MIN, MOY OU MAX de la strate 2 ne correspond pas a EPAIS_MIN, MOY ou MAX de la strate 1
1300663			25577				PROF_APPAR_MIN, MOY OU MAX de la strate 2 ne correspond pas a EPAIS_MIN, MOY ou MAX de la strate 1
1300664			25567				PROF_APPAR_MIN, MOY OU MAX de la strate 2 ne correspond pas a EPAIS_MIN, MOY ou MAX de la strate 1
1300665			22082				2 prof_appar_min de la strate N+1 ne peut etre < à prof_appar_min+epais_min de la strate N
1300666			22090				3 prof_appar_min de la strate N+1 ne peut etre < à prof_appar_min+epais_min de la strate N
1300667			22019				3 prof_appar_min de la strate N+1 ne peut etre < à prof_appar_min+epais_min de la strate N
1300668			22045				2 prof_appar_min de la strate N+1 ne peut etre < à prof_appar_min+epais_min de la strate N
1300669			22041				3 prof_appar_min de la strate N+1 ne peut etre < à prof_appar_min+epais_min de la strate N
1300670			22044				3 prof_appar_min de la strate N+1 ne peut etre < à prof_appar_min+epais_min de la strate N
1300713			25554	118			3 Cette strate ne présente pas de données quantitatives
1300714			25510	112			2 Cette strate ne présente pas de données quantitatives
1300724			22080	62			Pour chaque UTS, les strates doivent être numérotées de 1 à n avec pour la strate de surface le n° 1.
1300732			22019	1			Les UTS doivent être caractérisées par un profil (affectation dans l_profil_etude)
1300733			22020	2			Les UTS doivent être caractérisées par un profil (affectation dans l_profil_etude)
1300734			22021	3			Les UTS doivent être caractérisées par un profil (affectation dans l_profil_etude)
1300735			22022	4			Les UTS doivent être caractérisées par un profil (affectation dans l_profil_etude)
1300736			22024	6			Les UTS doivent être caractérisées par un profil (affectation dans l_profil_etude)

Gains de temps importants

Adaptable à d'autres bases de données

Suivi des justifications

Conclusions

L'unité est très impliquée dans la démarche qualité -> référentiel V2 INRA

- ✓ Mise en place d'un groupe qualité,
- ✓ Rédaction de documents qualité,

...

Un souci permanent

- ✓ De travailler en amont sur la qualité des informations : dérives analytiques, méthodologiques par des formations des personnels (à l'INRA et hors INRA), des documents explicatifs (notice, CC...),
- ✓ De prendre en compte les incertitudes sur les données (métadonnées),
- ✓ De tracer nos activités,
- ✓ D'insérer des informations de qualité,
- ✓ Et de fournir de la donnée de qualité.

Avec des points faibles

- ✓ Quantité et diversité de l'information
- ✓ Historique DoneSol important,
- ✓ Réseau de partenaires -> un contrôle impossible sur toutes les activités,
- ✓ nombreux opérateurs pour l'acquisition et la saisie,
- ✓ Une charge de travail très importante.