

STIC Environnement / 11-13 mai 2011 / Saint Etienne

Mines de Douai
LILLE EUROREGION

Session Apprentissage statistique et classification

Université Lille1
Sciences et Technologies

Ecole Nationale Supérieure des Mines
SAINT-ETIENNE

Un modèle de régression pour données censurées de retombées atmosphériques

Pascaud Aude^{1,3}, Roustant Olivier², Sauvage Stéphane^{1,3}, Coddeville Patrice^{1,3}
¹Ecole des Mines de Douai, Dépt. Chimie et Environnement, F-59500 Douai, France
²Ecole des Mines de Saint-Etienne, LSTI/CROCUS, F-42023 St-Etienne, France
³Université Lille Nord de France, F-59000 Lille, France

aude.pascaud@mines-douai.fr

Thèse de doctorat - **PROJET SESAME PRIMEQUAL2/PREDIT**
Directeur de thèse : Coddeville Patrice
Encadrants : Roustant Olivier - Sauvage Stéphane

Mines de Douai
LILLE EUROREGION

Plan de l'exposé

I. Introduction
II. Méthodologie
III. Résultats
IV. Conclusions
V. Perspectives

2

STIC Environnement / 11-13 mai 2011 / Saint - Etienne

Cadre de l'étude

Introduction

Transformations dans
les phases gazeuse, particulaire
et dans les gouttelettes nuageuses
 H_2SO_4 , HNO_3 , NH_4HSO_4 ...

Transport atmosphérique

SO_2 , NO_x , NH_3 , COV

Retombées humides
Retombées sèches

H^+ , SO_4^{2-} , NO_3^- , NH_4^+

Emissions

Chauffage, Production d'électricité,
Industries, Transports routiers, aérosols
marins, volcans ...



Ecosystèmes


terrestre et aquatique
Effets sur la faune et la flore



3

STIC Environnement / 11-13 mai 2011 / Saint - Etienne


Constat : Émissions Françaises



Réduction très importante SO_2 depuis 1980

Réduction moyenne NO_x depuis 1990

Réduction très faible NH_3 depuis 1980



France	SO_2	NO_x	NH_3
Estimations 2009	324	1215	746
Göteborg objectifs 2010 (Kt)	400	860	780
Directive 2001/81CE objectifs 2010 (Kt)	375	810	780

4


(CITEPA, 2010)

STIC Environnement / 11-13 mai 2011 / Saint - Etienne

Constat : des écosystèmes sensibles


charges critiques

« valeur d'exposition à un ou plusieurs contaminants en dessous de laquelle des effets significatifs sur des composantes sensibles de l'écosystème n'apparaissent pas, en l'état actuel des connaissances » (Nilsson et Grennfelt 1988)



RISQUE D'ACIDIFICATION LIÉE AU SOUFRE

Zones sensibles Zones peu sensibles



RISQUE D'EUTROPHISATION LIÉE À L'AZOTE

Zones sensibles Zones peu sensibles




5

(Probst et Leguédais, 2008)

STIC Environnement / 11-13 mai 2011 / Saint - Etienne

Observatoires de retombées atmosphériques



	Nombres de sites	Période d'observation
MERA	8	19 ans
CATAENAT	27	16 ans
BAPMON	3	31 ans

Trois observatoires ≠ modes de fonctionnement

Fréquences de prélèvements / Types de préleveurs / Méthodes d'analyses

Assurance qualité données

Suivi fonctionnement / Modes opératoires / Traçabilité échantillons / Intercomparaison

6

STIC Environnement / 11-13 mai 2011 / Saint - Etienne

PROJET SESAME – PRIMEQUAL2/PREDIT

Objectifs

BD : 20 ans chimie pluies 3 observatoires (MERA, CATAENAT, VAG)

- **Analyse préalable** : permettre la comparaison des bases
- **Tendances – Prévisions** : relier les stratégies de réduction d'émissions et les évolutions dans les retombées atmosphériques
- **Approche source-récepteur** : déterminer des profils chimiques et des contributions des sources d'émissions et les localiser
- **Approche géostatistique** : spatialiser les concentrations et les dépôts associés aux retombées atmosphériques, possibilité de relier avec l'analyse temporelle.
- **Développement méthodologique des charges critiques** : améliorer l'estimation et définir des cartes de dépassements selon les scénarios et les résultats obtenus par les étapes précédentes.

Points +

Base de données consistante
Approches multidisciplinaires et multipartenaires (EMD, EMSE, ECOLAB, ONF, METEO FRANCE)

Analyse préalable : comparabilité

OBJECTIFS

fort niveau de confiance à la donnée

-> données suspectes

limite de détection de la technique analytique

-> données censurées

Pouvoir détecter les valeurs suspectes

Définir des valeurs de remplacement des données censurées pour construire des moyennes mensuelles


Méthodes de Remplacement

METHODOLOGIE

	Effectif faible	Effectif important	Effectif très important
Utilisation exploratoire	LD/2 (si qq échantillons < LD)	LD/2 (si <15% des échantillons < LD)	Méthode de Cohen (distribution normale) Méthode Kaplan Meier (autres distributions)
Utilisation publication	Kaplan Meier	Kaplan Meier	Méthode de Cohen (distribution normale) Méthode Kaplan Meier (autres distributions)
Utilisation réglementaire	Utilisation publication	Kaplan Meier	Kaplan Meier




MERA → LD/2
CATAENAT → 0
VAG → LD



Limites de détection

cas du Mg²⁺ - station du Donon - Alsace


Taux de censure 35%



EVOLUTION TECHNIQUE DES MÉTHODES ANALYTIQUES

Log-normalité

cas du Mg2+ - station de Donon - le Bas-Rhin (Alsace)




11

STIC Environnement / 11-13 mai 2011 / Saint - Etienne

Saisonnalités

cas du Mg2+ - station de Donon - le Bas-Rhin (Alsace)



μ et σ sont ici estimés par les ordonnées à l'origine et les pentes des diagrammes précédents

12

STIC Environnement / 11-13 mai 2011 / Saint - Etienne

Conclusion et modélisation

Soient $y_1 = \log_{10}(C_1), \dots, y_n = \log_{10}(C_n)$

- Si $y(t) > L(t)$, $y(t)$ provient d'une loi $N(\mu(t), \sigma(t)^2)$

Dans la suite on fait l'hypothèse que ce résultat est encore valable lorsque $y(t) < L(t)$

modèle de régression linéaire tronqué

- généralisation du modèle de Tobit, 1958,
- et de celui de Liu et al, 1997, utilisé en chimie environnementale

Modèle de régression tronqué

Mathématiquement, on a :

$$y(t) = y^*(t) \quad \text{si} \quad y^*(t) \geq L(t)$$

$$y(t) = L(t) \quad \text{si} \quad y^*(t) < L(t)$$

avec :

$$y^*(t) = \mu(t) + \sigma(t)e(t), \quad t=1, \dots, n$$

et

$$\mu(t) = x(t)' \beta,$$

$$\sigma(t) = z(t)' \gamma \quad (>0)$$

$e(1), \dots, e(n)$ sont des v.a. indépendantes de loi $N(0,1)$

β et γ sont des paramètres à estimer

$x(t)$ and $z(t)$ sont des variables explicatives

Choix des variables explicatives

- Endogènes :
 - **Tendance**: monotone, affine par morceaux, ...
 - **Saisonnalités**: sous la forme de premiers termes d'une série de Fourier
par exemple : $\mu(t) = b_0 + b_1t + b_2\cos(wt) + b_3\sin(wt)$
- Exogènes:
 - Emissions des polluants, variables météorologiques ...

Valeurs suspectes et imputation


- Repérage de valeurs suspectes réalisé avec un calcul d'un quantile d'ordre élevé
Seuil utilisé : $\mu(t) + \Phi^{-1}(0.998)*\sigma(t)$
- Remplacement d'une valeur censurée par une **valeur** (imputation simple), obtenue par prévision, en généralisant la formule de Liu [Liu et al., 1997] au cas hétéroscédastique.
- Possibilité de reconstituer **toute la distribution** des données censurées par simulation

CAS D'UNE SÉRIE TRÈS CENSURÉE

APPLICATIONS

Repérage de valeurs suspectes


cas du Mg²⁺ - station de Donon - le Bas-Rhin (Alsace) n=2851 taux censure =35%



**Prise en compte des saisonnalités
-> repérage des données 902 et 7143**

CAS D'UNE SÉRIE TRÈS CENSURÉE


Remplacement de valeurs censurées



**Le résultat de l'imputation simple est ici
voisin de LD/2**

CAS D'UNE SÉRIE PEU CENSURÉE

valeurs censurées / suspectes



Le résultat de l'imputation simple est ici plus proche de LD

CONCLUSION

- détection saisonnière et automatique des valeurs suspectes
- valeur de remplacement saisonnière et moins arbitraire que LD/2
 - > *méthodologie appliquée au calcul de moyennes mensuelles*
- modèle adapté à l'incorporation de tendances (endogènes ou exogènes), prise en compte de la saisonnalité, de l'hétéroscédasticité des données

PERSPECTIVES

- calcul d'indicateurs statistiques
 - > *nécessite souvent de reconstituer la distribution des données censurées*
- définition de tendances et choix de variables exogènes
 - > *exemple : la hauteur de pluie*
- comparaison avec d'autres méthodes

REMERCIEMENTS

- Mireille Batton-Hubert et Djamel Mimoun, ainsi que les participants au séminaire interne EMSE du 20/01/2011 pour leur remarques constructives
- Tous les opérateurs des dispositifs de surveillance
- Ministère chargé de l'environnement et l'ADEME pour le financement du projet SESAME dans le cadre de PRIMEQUAL/PREDIT

MERCI DE VOTRE ATTENTION !!

CITEPA, "Les émissions dans l'air en France métropole – Substances relatives à l'acidification, l'eutrophisation et à la pollution photochimique." *Centre Interprofessionnel d'Etudes de la pollution Atmosphérique*, 17pp, 2009.

Liu S., Lu J.C., Kolpin D., and Meeker W., Analysis of environmental data with censored observations. *Environmental Science & Technology*, 31:3358–3362, 1997.

Probst A., Leguédois S. French National Focal Center report In: J-P. Hettelingh, M. Posch, J. Slootweg (eds.) *Critical Load, Dynamic Modelling and Impact Assessment in Europe, CCE Status Report 2008*, Coordination Center for Effects, RIVM, Bilthoven, pp. 134–140, 2008.

Tobin J., Estimation of relationships for limited dependent variables, *Econometrica*, vol. 26, p. 24-36, 1958.

U.S. Environmental Protection Agency, *Air toxics data analysis workbook*, disponible sur <http://www.epa.gov/ttnamti1/files/ambient/airtox/workbook/AirToxicsWorkbook6-09.pdf>, 2009. dernière consultation 11/05/2011