

# Agrégation séquentielle pour la prévision de la qualité de l'air

Vivien Mallet<sup>1,2</sup>, Bruno Sportisse<sup>1,2</sup>,  
Gilles Stoltz<sup>3,4</sup>, Boris Mauricette,  
Sébastien Gerchinovitz<sup>3,1</sup>

Journées MAS de la SMAI  
29 août 2008

<sup>1</sup> INRIA

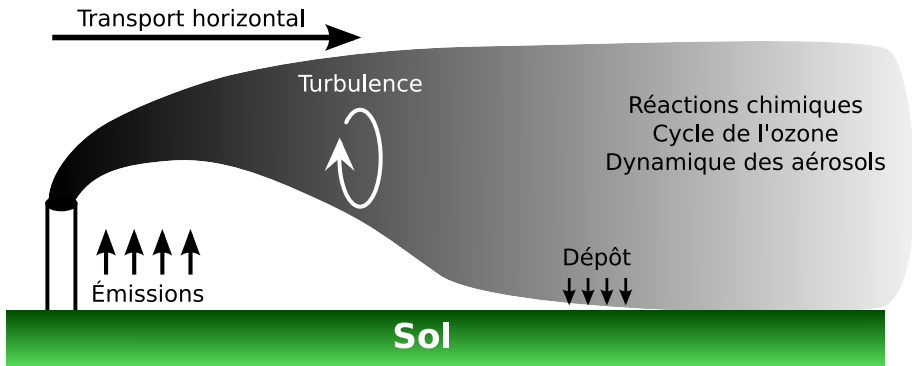
<sup>2</sup> CERE, laboratoire commun ENPC - EDF R&D, Université Paris-Est

<sup>3</sup> CNRS & DMA, École normale supérieure

<sup>4</sup> HEC Paris

Projet ANR ATLAS, « From Applications to Theory in Learning and Adaptive  
Statistics »

# Modèles de chimie-transport pour la qualité de l'air




$$\forall i \quad \frac{\partial c_i}{\partial t} = \underbrace{-\operatorname{div}(Vc_i)}_{\text{advection}} + \underbrace{\operatorname{div}\left(\rho K \nabla \frac{c_i}{\rho}\right)}_{\text{diffusion}} + \underbrace{\chi_i(c, t)}_{\text{chimie}} + \underbrace{S_i - P_i}_{\text{sources and pertes}}$$


$c_i(t, x, y, z)$  : concentration du polluant  $i$

# Prévision de l'ozone à l'échelle européenne


Carte d'ozone ( $\mu\text{g m}^{-3}$ , 24 septembre 2006, 16h UT)



# Performance des modèles pour les pics d'ozone

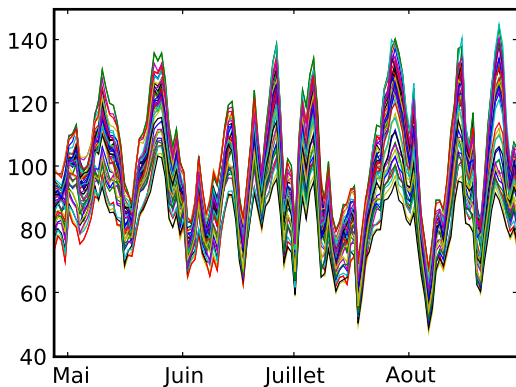


Un réseau d'observation européen



Performance moyenne  
(station à Saint Nazaire)

# Ensemble de prévisions



Ensemble de prévisions de pics d'ozone (station Saint Nazaire)  
48 modèles physiques, soit 48 experts

# Agrégation séquentielle

## Notations

Prédiction de l'expert  $m$  à l'échéance  $t$  et à la station  $s$  :  $\mathbf{x}_{m,t}^s$

Observation :  $\mathbf{y}_t^s$

Prédiction agrégée :  $\hat{\mathbf{y}}_t^s = \sum_{m=1}^N \alpha_{m,t} \mathbf{x}_{m,t}^s$

Vecteurs  $\mathbf{y}_t$ ,  $\mathbf{x}_{m,t}$  et  $\hat{\mathbf{y}}_t$  des valeurs aux  $S$  stations

## Notes

- 1 Combinaison convexe ou non
- 2 Les poids ne dépendent pas de la station, pour autoriser une agrégation autour des stations d'observation
- 3 Les poids  $\alpha_{m,t}$  peuvent dépendre de  $\mathbf{y}_1, \dots, \mathbf{y}_{t-2}, \mathbf{y}_{t-1}$  et  $\mathbf{x}_{m',1}, \dots, \mathbf{x}_{m',t-1}, \mathbf{x}_{m',t}$  (pour tout  $m'$ )
- 4 Aucune hypothèse stochastique

# Agrégation séquentielle

## Notations

- Poids :  $\alpha_{m,t} = \mathcal{F}_{m,t}(\mathbf{y}_1, \dots, \mathbf{y}_{t-2}, \mathbf{y}_{t-1}, \mathbf{x}_{m',1}, \dots, \mathbf{x}_{m',t-1}, \mathbf{x}_{m',t})$
- Combinaison :  $\hat{\mathbf{y}}_t^s = \sum_m \alpha_{m,t} \mathbf{x}_{m,t}^s$
- Perte instantanée (à  $t$ ) :  $L(\hat{\mathbf{y}}_t, \mathbf{y}_t) = \sum_s (\hat{\mathbf{y}}_t^s - \mathbf{y}_t^s)^2$

## Principe de l'agrégation séquentielle

- Borner le regret

$$\sum_{t \leq n} L(\hat{\mathbf{y}}_t, \mathbf{y}_t) - \min_{\beta} \sum_{t \leq n} L\left(\sum_m \beta_m \mathbf{x}_{m,t}, \mathbf{y}_t\right)$$

- Si le regret est en  $o(n)$  :

$$\frac{1}{Sn} \sum_{t \leq n} L(\hat{\mathbf{y}}_t, \mathbf{y}_t) - \frac{1}{Sn} \min_{\beta} \sum_{t \leq n} L\left(\sum_m \beta_m \mathbf{x}_{m,t}, \mathbf{y}_t\right) \xrightarrow{n \rightarrow \infty} 0$$

# Agrégation séquentielle

EG : exponentielle des gradients (Vovk, 1990)

- Combinaison EG :  $\hat{\mathbf{y}}_t^s = \sum_m \alpha_{m,t} \mathbf{x}_{m,t}^s$
- Perte instantanée (à  $t$ ) :  $L(\hat{\mathbf{y}}_t, \mathbf{y}_t) = \sum_s (\hat{\mathbf{y}}_t^s - y_t^s)^2$
- Poids initiaux ( $t = 1$ ) :  $\forall m \quad \alpha_{m,1} = \frac{1}{N}$
- Poids à  $t > 1$  :

$$\forall m \quad \alpha_{m,t} = \exp \left( -\eta \sum_{t' < t} \frac{\partial L(\hat{\mathbf{y}}_{t'}, \mathbf{y}_{t'})}{\partial \alpha_{m,t'}} \right) \times \text{normalisation}$$

- Borne sur le regret

$$\sum_{t \leq n} L(\hat{\mathbf{y}}_t, \mathbf{y}_t) - \min_{\beta} \sum_{t \leq n} L\left(\sum_m \beta_m \mathbf{x}_{m,t}, \mathbf{y}_t\right) \leq \gamma S \sqrt{n \ln N}$$

où  $\forall m, t \quad \gamma \geq \left| \frac{\partial L(\hat{\mathbf{y}}_t, \mathbf{y}_t)}{\partial \alpha_{m,t}} \right|$



# Agrégation séquentielle

Régression ridge (Vovk, 2001, et Azoury et Warmuth, 2001)

- Combinaison RR :  $\hat{y}_t^s = \sum_m \alpha_{m,t} \mathbf{x}_{m,t}^s$
- Perte instantanée (à  $t$ ) :  $L(\hat{\mathbf{y}}_t, \mathbf{y}_t) = \sum_s (\hat{y}_t^s - y_t^s)^2$
- Calcul des poids :

$$\alpha_{.,t} = \operatorname{argmin}_{\beta} \left[ \sum_{t' < t} \sum_s \left( \sum_m \beta_m \mathbf{x}_{m,t'}^s - y_{t'}^s \right)^2 + \lambda \|\beta\|_2^2 \right]$$

- Borne sur le regret

$$\sum_{t \leq n} L(\hat{\mathbf{y}}_t, \mathbf{y}_t) - \min_{\beta} \sum_{t \leq n} L\left(\sum_m \beta_m \mathbf{x}_{m,t}, \mathbf{y}_t\right) \lesssim O(\ln n)$$

Cesa-Bianchi & Lugosi, *Prediction, Learning, and Games*, 2006

# Aggrégation séquentielle : variantes

## Exemple de la régression ridge

$$\alpha_{.,t} = \operatorname{argmin}_{\beta} \left[ \lambda \|\beta\|_2^2 + \sum_{t' < t} \sum_s \left( \sum_m \beta_m x_{m,t'}^s - y_{t'}^s \right)^2 \right]$$

## Escompte

Idée : atténuer l'influence du passé lointain

$$\alpha_{.,t} = \operatorname{argmin}_{\beta} \left[ \lambda \|\beta\|_2^2 + \sum_{t' < t} \sum_s (1 + \psi_{t-t'}) \left( \sum_m \beta_m x_{m,t'}^s - y_{t'}^s \right)^2 \right]$$

où  $\psi_j$  est une suite décroissante, par exemple  $\psi_j = \frac{100}{j^2}$

## Méta-apprentissage

# Application (score : RMSE, $\mu\text{g m}^{-3}$ )


## Pics d'ozone

	Réseau 1	Réseau 2	Réseau 3
Meilleur expert	22.43	21.90	23.87
EG	21.47	21.05	24.12
RR escomptée	<b>19.45</b>	<b>18.12</b>	<b>20.88</b>
$C_\alpha$	19.24	18.16	20.26


## Concentrations horaires d'ozone

	Réseau 1	Réseau 2	Réseau 3
Meilleur expert	26.68	25.98	28.45
EG	24.31	24.67	26.01
RR escomptée	<b>22.02</b>	<b>22.82</b>	<b>22.27</b>
$C_\alpha$	22.80	23.52	23.19

# Évolution temporelle des poids



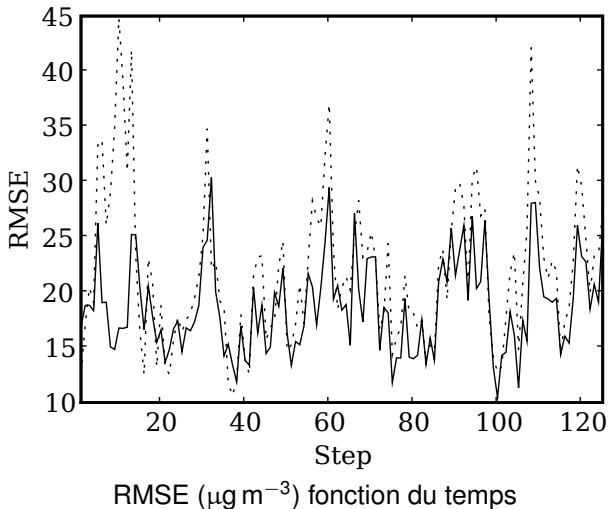
EG



RR escomptée


# Application

## Robustesse



# Application

Comportement pour les événements extrêmes



Fréquence avec laquelle RR escomptée prévoit mieux que le meilleur modèle

# Un mot sur l'assimilation de données « classique »

## Exemple : le filtre de Kalman

- Vecteur d'état à l'échéance  $t$  :  $\mathbf{e}_t^f$
- Correction du filtre (analyse) :  $\mathbf{e}_t^a = \mathbf{e}_t^f + K_t(\mathbf{o}_t - H_t\mathbf{e}_t^f)$
- Prévision  $\mathbf{e}_{t+1}^f = \mathcal{M}_{t \rightarrow t+1}(\mathbf{e}_t^a)$ , et propagation *approximée* de la matrice de covariance d'erreur

## Différences avec l'agrégation séquentielle

	Assimilation classique	Apprentissage
Paramètres	grand nombre	très peu
Théorie & application	fortes limitations	compatibles
Spatialisation	naturelle	hors cadre

# Conclusion

## Stratégie

- Ensemble de prédictions de modèles physiques ou experts
- Agrégation séquentielle
- Performances de la meilleure combinaison linéaire d'experts

## Positionnement en terme de modélisation


- Statistiques pures / agrégation séquentielle / assimilation classique

## La suite...


- Seuils sur les poids, LASSO
- Sélection des experts (modèles coûteux)
- Spatialisation




## Number of Models (*RR* with Discount)




# Number of Models (*ELS a posteriori*)



# Per Station



# Models RMSEs



# Ensemble Spread

