

Comment tirer parti de l'embaras du choix face à plusieurs modèles de prévision concurrents

Gilles Stoltz

CNRS — École normale supérieure — HEC Paris



Qu'est-ce que la statistique ?

Deux branches ?

- Statistiques **descriptives** (bien représenter et résumer des données, mieux connaître l'échantillon)
- Statistique **inférentielle** (mieux connaître une population ou comprendre un phénomène à partir de ces données)

Dans les deux cas : connaître, comprendre, ...

Mais dans quel but ? **Prévoir**, prendre des décisions.

Prévoir, ce n'est pas prédire : ce qui distingue la **statistique** de la **voyance**, c'est qu'elle s'appuie sur des données.

Bon. Traiter des données de sondage, c'est facile à expliquer.

Mais expliquer comment construire des modèles de prévision statistique de la consommation électrique ?

C'est toute une industrie. Chacun y va de son (petit ou gros) modèle. Tous des usines à gaz. Et c'est pourquoi...

Cadre de cet exposé

Le mot-clé sera : «agrégation» (par opposition à «sélection»)

Un statisticien accepte la mission de prévoir une suite y_1, y_2, \dots d'observations vivant dans un intervalle $[0, B]$.

Ses prévisions $\hat{y}_1, \hat{y}_2, \dots$ sont formées dans $[0, B]$ également, car B est supposé connu.

Les observations et prévisions (1) sont effectuées de manière **séquentielle** et (2) ne reposent sur **aucun modèle stochastique**.

(1) signifie qu'à chaque échéance, la prévision \hat{y}_t pour y_t est déterminée


- sur le seul fondement du passé, $y_1^{t-1} = (y_1, \dots, y_{t-1})$,
- et avant que la vraie valeur y_t ne soit révélée au grand jour.

(2) indique qu'on ne se placera pas dans un cas où les y_t sont les réalisations d'un processus stochastique Y_t sous-jacent.

Tant mieux pour vous qui n'avez pas peut-être pas étudié la théorie des probabilités !

Pour que le problème ait un sens dans un cadre aussi général, on suppose avoir accès à des **experts**, en nombre fini N .

C'est le petit nom des fameux «modèles de prévisions concurrents».



A chaque échéance t , l'expert $j \in \{1, \dots, N\}$ forme une prévision

$$f_{j,t} = f_{j,t}(y_1^{t-1}) \in [0, B]$$

Le statisticien fonde maintenant ses propres prévisions \hat{y}_t sur

- les **observations passées** : $y_1^{t-1} = (y_1, \dots, y_{t-1})$,
- et sur les **conseils passés et présents** des experts :
 $f_{j,s}$ pour $s \in \{1, \dots, t\}$ et $j \in \{1, \dots, N\}$.

Méthode : combinaisons convexes à poids variables

Le statisticien va former à chaque tour des prévisions (dites agrégées) de la forme

$$\hat{y}_t = \sum_{j=1}^N p_{j,t} f_{j,t} \quad \text{où} \quad \begin{cases} \forall j, p_{j,t} \geq 0, \\ p_{1,t} + \dots + p_{N,t} = 1 \end{cases}$$

C'est ce que l'on appelle une combinaison convexe selon $\mathbf{p}_t = (p_{1,t}, \dots, p_{N,t})$.

L'**objectif** du statisticien est de prévoir, en moyenne, presque'aussi bien que la **meilleure combinaison convexe** constante \mathbf{q} des prévisions des experts.

Mais il s'agit tout d'abord de quantifier la précision d'une (suite de) prévision(s)...

On introduit une **fonction de perte** $\ell : [0, B] \times [0, B] \rightarrow \mathbb{R}_+$.

Elle mesure l'écart entre une prévision \hat{y} et une observation y .

Des choix typiques sont

- la perte quadratique $\ell(\hat{y}, y) = (\hat{y} - y)^2$;
- la perte absolue $\ell(\hat{y}, y) = |\hat{y} - y|$;
- le pourcentage d'erreur $\ell(\hat{y}, y) = |\hat{y} - y|/|y|$.

On retiendra la **perte quadratique** pour la suite (par exemple parce qu'elle permet de pénaliser davantage les erreurs de prévisions importantes).

On définit les perte **cumulée** et **moyenne** du statisticien comme

$$\hat{L}_T = \sum_{t=1}^T \left(\sum_{j=1}^N p_{j,t} f_{j,t} - y_t \right)^2 \quad \text{et} \quad \widehat{\text{EQM}}_T = \sqrt{\frac{\hat{L}_T}{T}}$$

On a défini les perte **cumulée** et **moyenne** du statisticien :

$$\widehat{L}_T = \sum_{t=1}^T \left(\sum_{j=1}^N p_{j,t} f_{j,t} - y_t \right)^2 \quad \text{et} \quad \widehat{\text{EQM}}_T = \sqrt{\frac{\widehat{L}_T}{T}}$$

Pour une combinaison convexe constante $\mathbf{q} = (q_1, \dots, q_N)$:

$$L_T(\mathbf{q}) = \sum_{t=1}^T \left(\sum_{j=1}^N q_j f_{j,t} - y_t \right)^2 \quad \text{et} \quad \text{EQM}_T(\mathbf{q}) = \sqrt{\frac{L_T(\mathbf{q})}{T}}$$

EQM signifie «**écart quadratique moyen**».

Le **regret** est la différence entre les deux quantités cumulées

$$R_T = \widehat{L}_T - \min_{\mathbf{q}} L_T(\mathbf{q}) \quad \text{ou} \quad \widehat{L}_T = \min_{\mathbf{q}} L_T(\mathbf{q}) + R_T$$

Comme $\sqrt{a+b} \leq \sqrt{a} + \sqrt{b}$, il vient également

$$\widehat{\text{EQM}}_T \leq \text{EQM}_T(\mathbf{q}) + \sqrt{R_T/T}$$

Morale : il faut assurer que R_T/T tende vers 0 (ou soit négatif).

On rappelle que le **regret** R_T est défini comme la différence

$$\widehat{L}_T - \min_{\mathbf{q}} L_T(\mathbf{q}) = \sum_{t=1}^T \left(\sum_{j=1}^N p_{j,t} f_{j,t} - y_t \right)^2 - \min_{\mathbf{q}} \sum_{t=1}^T \left(\sum_{j=1}^N q_j f_{j,t} - y_t \right)^2$$

On veut construire des stratégies de prévision telles que le **regret moyen** converge vers 0, de manière uniforme :

$$\limsup_{T \rightarrow \infty} \frac{1}{T} \sup \left\{ \widehat{L}_T - \min_{\mathbf{q}} L_T(\mathbf{q}) \right\} \leq 0$$

où le supremum porte sur **toutes les suites** possibles d'observations et de prévisions des experts. (Pas juste sur la plupart d'entre elles !)

Remarques :

- On parle de prévision de **suites individuelles** ou d'**agrégation robuste**.
- La meilleure combinaison convexe \mathbf{q}^* ne peut être déterminée que **rétrospectivement** tandis que le statisticien est assujéti à une contrainte de prévision **séquentielle**.

Ce cadre admet une interprétation **méta-statistique** :

- chaque **expert** peut correspondre à une méthode de prévision **statistique** fondamentale ; des méthodes concurrentes peuvent être considérées ;
- on **combine** ensuite de manière **robuste** (et déterministe) ces prévisions fondamentales.

Or, la **perte cumulée** et l'**écart quadratique moyen** du statisticien peuvent être décomposés selon

$$\widehat{L}_T = \min_{\mathbf{q}} L_T(\mathbf{q}) + R_T \quad \text{et} \quad \widehat{\text{EQM}}_T \leq \text{EQM}_T(\mathbf{q}) + \sqrt{R_T/T}$$

On peut donc interpréter

- le terme de performance de la meilleure combinaison convexe des experts comme une **erreur d'approximation**,
- le terme de regret comme mesurant une **difficulté d'estimation** séquentielle.

Une stratégie simple

Que nous allons étudier de bout en bout !

Rappel de l'objectif de prévision :

Il s'agit donc de **majorer** uniformément le **regret** face à toutes les combinaisons convexes \mathbf{q} ,

$$\sum_{t=1}^T \left(\sum_{j=1}^N p_{j,t} f_{j,t} - y_t \right)^2 - \sum_{t=1}^T \left(\sum_{j=1}^N q_j f_{j,t} - y_t \right)^2$$

Inégalité utile : pour tous $u, v \in [0, B]$,

$$u^2 - v^2 \leq 2u(u - v)$$

Preuve : $u^2 - v^2 = (u + v)(u - v)$ et distinguer selon $u \geq v$ ou $u \leq v$ pour savoir s'il faut majorer ou minorer $u + v$ par $2u$.

On peut généraliser cette inégalité (dite «des pentes») à d'autres fonctions de pertes («**convexes**»).

Il s'agit de **majorer** uniformément le **regret** face à toutes les combinaisons convexes \mathbf{q} :

$$\begin{aligned}
 & \max_{\mathbf{q}} \sum_{t=1}^T \left(\sum_{j=1}^N p_{j,t} f_{j,t} - y_t \right)^2 - \sum_{t=1}^T \left(\sum_{j=1}^N q_j f_{j,t} - y_t \right)^2 \\
 & \leq \max_{\mathbf{q}} \sum_{t=1}^T 2 \left(\sum_{k=1}^N p_{k,t} f_{k,t} - y_t \right) \left(\sum_{j=1}^N p_{j,t} f_{j,t} - \sum_{j=1}^N q_j f_{j,t} \right) \\
 & = \max_{\mathbf{q}} \sum_{t=1}^T \left(\sum_{j=1}^N p_{j,t} \tilde{\ell}_{j,t} - \sum_{j=1}^N q_j \tilde{\ell}_{j,t} \right) \\
 & = \sum_{t=1}^T \sum_{j=1}^N p_{j,t} \tilde{\ell}_{j,t} - \min_{i=1, \dots, N} \sum_{t=1}^T \tilde{\ell}_{i,t}
 \end{aligned}$$

où l'on a défini

$$\tilde{\ell}_{j,t} = 2 \left(\sum_{k=1}^N p_{k,t} f_{k,t} - y_t \right) f_{j,t} \in [-2B^2, 2B^2]$$

Via la considération des pseudo-pertes (**signées**) $\tilde{\ell}_{j,t}$, on vient de se ramener au **cadre générique** suivant d'apprentissage séquentiel.

A chaque tour $t = 1, 2, \dots$,

- le statisticien choisit un vecteur de combinaison convexe $\mu_t = (\mu_{1,t}, \dots, \mu_{N,t})$;
- l'environnement détermine un vecteur de pertes $\ell_t = (\ell_{1,t}, \dots, \ell_{N,t})$, tel que $\ell_{j,t} \in [m, M]$ pour tout j ;
- le statisticien observe ℓ_t .

L'objectif est de contrôler uniformément le **regret** générique

$$R_T = \sum_{t=1}^T \sum_{j=1}^N \mu_{j,t} \ell_{j,t} - \min_{i=1, \dots, N} \sum_{t=1}^T \ell_{i,t}$$

Pour tout $j \in \{1, \dots, N\}$, on prend $\mu_{j,1} = 1/N$ et pour $t \geq 2$,

$$\mu_{j,t} = \frac{\exp\left(-\eta \sum_{s=1}^{t-1} \ell_{j,s}\right)}{\sum_{k=1}^N \exp\left(-\eta \sum_{s=1}^{t-1} \ell_{k,s}\right)}$$

C'est la stratégie de **pondération par poids exponentiels** des pertes passées des experts (de vitesse d'apprentissage η).

Lemme. On fixe deux réels $m \leq M$.

Pour tout $\eta > 0$ et pour toute **suite individuelle** d'éléments $\ell_{j,t} \in [m, M]$, où $j \in \{1, \dots, N\}$ et $t \in \{1, \dots, T\}$,

$$R_T = \sum_{t=1}^T \sum_{j=1}^N \mu_{j,t} \ell_{j,t} - \min_{i=1, \dots, N} \sum_{t=1}^T \ell_{i,t} \leq \frac{\ln N}{\eta} + \eta \frac{(M - m)^2}{8} T$$

Références : Vovk '90 et Littlestone et Warmuth '94

Éléments de preuve

1. Borne sous-optimale

$$\frac{\ln N}{\eta} + \eta \frac{(M - m)^2}{2} T$$

à partir de $e^{-x} \leq 1 - x + x^2/2$, inégalité valable pour tout $x \geq 0$

2. Borne avec le facteur $1/8$ par le lemme de Hoeffding : pour toute variable aléatoire X à valeurs dans $[m, M]$, pour tout $s \in \mathbb{R}$,

$$\ln \mathbb{E}[e^{sX}] \leq s \mathbb{E}[X] + \frac{s^2}{8} (M - m)^2$$

Le diable est dans les détails...

On rappelle que $[m, M]$ est l'intervalle des pertes.

On peut **optimiser** la borne sur le regret en η :

$$R_T \leq \min_{\eta > 0} \left\{ \frac{\ln N}{\eta} + \eta \frac{(M - m)^2}{8} T \right\} = (M - m) \sqrt{\frac{T}{2} \ln N}$$

pour le choix de

$$\eta^* = \frac{1}{M - m} \sqrt{\frac{8 \ln N}{T}}$$

Ce choix dépend de M et m , qui sont connus à l'avance, mais également de T , qui est destiné à tendre vers l'infini.

Or, aucune valeur fixée de $\eta > 0$ n'assure que $R_T = o(T)$.

On n'a donc pas encore de stratégie **totale**ment séquentielle.

Les solutions possibles sont, d'une part, de recourir à des **re-démarrages à froid** périodiques.

D'autre part, de faire **varier** les vitesses d'apprentissage au cours du temps, en fonction du passé : pour $t \geq 2$,

$$\mu_{j,t} = \frac{\exp\left(-\eta_t \sum_{s=1}^{t-1} \ell_{j,s}\right)}{\sum_{k=1}^N \exp\left(-\eta_t \sum_{s=1}^{t-1} \ell_{k,s}\right)}$$

Un bon choix des η_t permet alors d'obtenir la borne de regret

$$R_T \leq (M - m) \sqrt{T \ln N}$$

Le **prix** à payer pour l'**adaptation** à T est donc un facteur multiplicatif $\sqrt{2}$.

Le réglage théorique proposé pour les η_t conduit à de **mauvaises performances** pratiques.

La stratégie \mathcal{E}_η de pondération par poids exponentiels des pertes, de vitesse d'apprentissage η , choisit la combinaison convexe $\mu_t(\eta)$:

$$\mu_{j,t}(\eta) = \frac{\exp\left(-\eta \sum_{s=1}^{t-1} \ell_{j,s}\right)}{\sum_{k=1}^N \exp\left(-\eta \sum_{s=1}^{t-1} \ell_{k,s}\right)}$$

La perte cumulée de cette stratégie vaut $\hat{L}_T(\eta) = \sum_{t=1}^T \sum_{j=1}^N \mu_{j,t}(\eta) \ell_{j,t}$

A partir de la famille des \mathcal{E}_η , on construit la méta-stratégie **calibrée** sur les données qui, à chaque échéance $t \geq 2$, utilise

$$\mu_t(\eta_t) \quad \text{où} \quad \eta_t \in \underset{\eta > 0}{\arg \min} \hat{L}_{t-1}(\eta)$$

Problème à résoudre

Exhiber une borne **théorique** sur le regret de la méta-stratégie !

Contre un **environnement changeant** la performance de toute combinaison convexe \mathbf{p} fixée peut être mauvaise.

On voudrait plutôt pouvoir se comparer à des suites de combinaisons convexes de la forme

$$\underline{\mathbf{p}} = (\mathbf{p}^1, \dots, \mathbf{p}^1, \mathbf{p}^2, \dots, \mathbf{p}^2, \dots, \mathbf{p}^{m+1}, \dots, \mathbf{p}^{m+1}),$$

où parmi les T éléments, au plus m **sauts** peuvent survenir.

Il existe des stratégies d'agrégation séquentielle dont le regret moyen face à ce genre de suites est asymptotiquement négatif ou nul.

Elles sont dites **par redistribution** au vu de leur manière de procéder (mise à jour exponentielle des poids suivie d'un mélange avec la loi uniforme).

Elles dépendent de deux paramètres η et α .

Deux domaines d'application pratique

- Préviation de la qualité de l'air
- Préviation de la consommation électrique

Plan des études empiriques

- (1) Construire des experts (sur données historiques, et utiliser un autre jeu de données pour les évaluer ainsi que nos méthodes)
- (2) Evaluer leurs performances rétrospectives par calculs d'**oracles** : meilleur expert, meilleure combinaison convexe, meilleure combinaison linéaire
- (3) Tabuler les performances de nos stratégies en fonction de **valeurs fixées** de leurs paramètres (η et α)
- (4) Voir ce que leurs versions **opérationnelles** auraient valu (les méta-stratégies calibrées, qui choisissent séquentiellement les paramètres au vu des données)

Première étude : Préviation de la qualité de l'air

Date de début : Septembre 2005

Partenaire académique : Vivien Mallet, INRIA, équipe CLIME

Partenaire industriel : Edouard Debry, INERIS (Institut National de l'EnviRonnement Industriel et des RisqueS)

Stagiaires de M2 contributeurs :

- Boris Mauricette (6 mois en 2007)
- Sébastien Gerchinovitz (5 mois en 2008)
- Karim Drifi (4 mois en 2009)
- Paul Baudin (4 mois en 2012)

Publications : dans *Journal of Geophysical Research*



Quelques caractéristiques de l'un des jeux de données étudié :

- Été 2001, période de 126 jours, prévision à 24h
- 241 stations en France et en Allemagne
- Concentrations typiques entre $40 \mu\text{g m}^{-3}$ et $150 \mu\text{g m}^{-3}$, seuils d'alerte à $180 \mu\text{g m}^{-3}$ et $240 \mu\text{g m}^{-3}$
- 48 experts, construits par Mallet et Sportisse '06, en faisant varier la formulation physico-chimique, le jeu de données d'entrée et le schéma de résolution numérique des EDPs

On mesure la qualité des prévisions avec une perte quadratique et on reportera des écarts quadratiques moyens (EQM).

Les stations du réseau sont indexées par \mathcal{S} .

Chaque modèle $j = 1, \dots, 48$ prévoit $f_{j,t}^s$ pour le pic d'ozone à la station s et au jour t , une valeur à comparer à l'observation y_t^s .

Le statisticien choisit à chaque tour une unique combinaison convexe $\mathbf{p}_t = (p_{1,t}, \dots, p_{N,t})$ pour agréger les experts à **toutes les stations**; on obtient ainsi des champs de prévision.

La perte associée à la combinaison convexe \mathbf{p}_t au tour t est


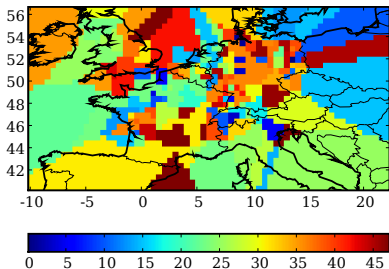
$$\ell_t(\mathbf{p}_t) = \sum_{s \in \mathcal{S}_t} \left(\sum_{j=1}^{48} p_{j,t} f_{j,t}^s - y_t^s \right)^2$$

où \mathcal{S}_t est le sous-ensemble des stations actives au jour t .

L'écart quadratique moyen vaut alors $\widehat{\text{EQM}}_T = \sqrt{\frac{\sum_{t=1}^T \ell_t(\mathbf{p}_t)}{\sum_{t=1}^T |\mathcal{S}_t|}}$

Gauche : Plusieurs experts sont bons et utiles.

Droite : Leurs profils de prévision sont fort différents (les experts ne sont pas une armée de clones !).



Gauche : Coloriage de l'Europe en fonction de l'index du meilleur expert local

Droite : Profils de prévision moyens (moyennes en temps et en espace)

EQM / Performances des experts

| Moyenne experts | Meilleur expert | Meilleur p |
|-----------------|-----------------|--------------|
| 24.41 | 22.43 | 21.45 |

EQM / Performance de la pondération par poids exponentiels
(avec meilleurs paramètres rétrospectifs)

| Version originelle | Version fenêtrée | Version escomptée |
|--------------------|------------------|-------------------|
| 21.47 | 21.37 | 21.31 |


La version **fenêtrée** de fenêtre H utilise uniquement les pertes des H derniers tours.

La version **escomptée** accorde plus d'importance aux pertes les plus récentes (mais considère encore toutes les pertes).

Méta-stratégie calibrée (version originelle) : EQM de **21.77**

Les méthodes d'agrégation séquentielle ne se concentrent **pas** sur un seul expert.

Les poids attribués aux modèles peuvent changer rapidement et de manière significative au cours du temps ; cela illustre la **variabilité** en temps des performances des experts.



Combinaisons convexes produites au cours du temps par la stratégie de pondération par poids exponentiels.

Deuxième étude : Prédiction de la consommation électrique

Date de début : Mars 2009

Partenaire industriel : Yannig Goude, EDF R&D

Stagiaires de M2 contributeurs :

- Marie Devaine (5 mois en 2009)
- Pierre Gaillard (5 mois en 2011)

Publication : dans *Machine Learning*





On dispose d'**experts spécialisés**, ne procurant des prévisions que dans certaines circonstances : par exemple, uniquement en semaine ou uniquement le week-end.

Il faut étendre les définitions et stratégies générales (détails omis).

Sur notre jeu de données de consommation globale en France, à pas demi-horaire,

- 24 experts sont disponibles, issus de 3 familles, chacune associée à un type de modèle (paramétrique, semi-paramétrique, non-paramétrique) ;
- il existe une contrainte opérationnelle de prévision à 24h (soit **48 échéances simultanées**).



Consommation électrique en France

- Année 2007–08 (gauche)
- Semaine typique hors hiver (droite)

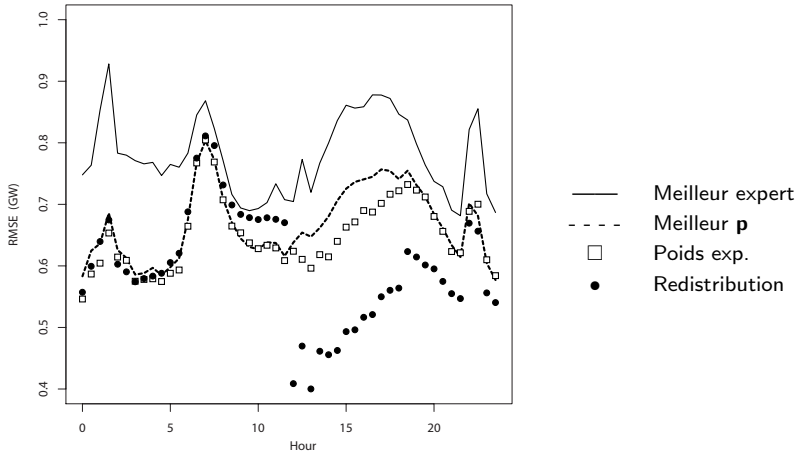
Quelques **ordres de grandeur** pour mieux saisir le problème.

| Echéances | Toutes les 30 minutes |
|-------------------------|-----------------------|
| Nombre de jours D | 320 |
| Nombre d'échéances T | 15 360 (= 320 × 48) |
| Nombre d'experts N | 24 (= 15 + 8 + 1) |
| Médiane des y_t | 56 330 MW |
| Borne B sur les y_t | 92 760 MW |

On précise là encore des EQM.

| | | |
|-----------------|-----------------|--------------|
| Meilleur expert | Moyenne experts | Meilleur p |
| 782 | 724 | 658 |
| Poids exp. | Meilleur param. | Opérat. |
| | 629 | 637 |

| | | | |
|----------------|-----------------------|-----------------|----------|
| Sauts | $m = T - 1 = 15\ 359$ | $m = 200$ | $m = 50$ |
| | 223 | 414 | 534 |
| Redistribution | | Meilleur param. | Opérat. |
| | | 5999 | 629 |




EQMs moyen (en GW / pas en MW) en fonction de la demi-heure

Les EQMs des deux stratégies étaient similaires mais leurs comportements **diffèrent** assez fortement au cours d'une journée.

Bibliographie

Juste au cas où vous n'en auriez pas déjà assez...


Le petit livre rouge



Prediction, Learning, and Games

Nicolò Cesa-Bianchi et Gábor Lugosi

J'ai publié un article de survol (en français !) dans le **Journal de la Société Française de Statistique**



Journal de la Société Française de Statistique
Vol. 151 No. 2 (2010)

Agrégation séquentielle de prédicteurs : méthodologie générale et applications à la prévision de la qualité de l'air et à celle de la consommation électrique

Title: Sequential aggregation of predictors. General methodology and application to air-quality forecasting and to the prediction of electricity consumption

Gilles Stoltz *

Résumé : Cet article fait suite à la conférence que j'ai eu l'honneur de donner lors de la réception de prix Marie-Anne Lavoine Dubouché, dans le cadre des "XX" Journées de Statistique à Orléans, en 2008. Il pose en revue les situations fondamentales, ainsi que quelques résultats récents, en prévision séquentielle de séries individuelles par agrégation d'experts. Il discute ensuite la méthodologie ainsi décrite en deux jeux de données. L'un pose un problème de prévision de qualité de l'air, l'autre pose une question de prévision de consommation électrique. La plupart des résultats mentionnés dans cet article reposent sur des travaux en collaboration avec Yanying Goude (IEP-RIED) et Vivien Maller (INRIA), ainsi qu'avec les collègues de monier que nous avons co-écrits : Marie-Dominique, Sébastien Gschwendtner et Boris Manakovic.

Abstract: This paper is an extended written version of the talk I delivered at the "XX" Journées de Statistique" in Orléans, 2008, when being awarded the Marie-Anne Lavoine Dubouché prize. It is devoted to surveying some fundamental as well as some more recent results in the field of sequential prediction of individual sequences with expert advice. It then presents two empirical studies following the stated general methodology: the first one is air-quality forecasting and the second one is the prediction of electricity consumption. Most results mentioned in the paper are based on joint works with Yanying Goude (IEP-RIED) and Vivien Maller (INRIA), together with some studies whom we co-organized for their M.Sc. thesis: Marie-Dominique, Sébastien Gschwendtner and Boris Manakovic.

Classification AMS 2000 : primaire 62-02, 62L99, 62P12, 62P30

Mots-clés : Agrégation séquentielle, prévision avec experts, séries individuelles, prévision de la qualité de l'air, prévision de la consommation électrique

Keywords: Sequential aggregation of predictors, prediction with expert advice, individual sequences, air-quality forecasting, prediction of electricity consumption

* Ecole normale supérieure, CNRS, 45 rue de Linn, 75005 Paris
IRIE, Paris, CNRS, 1 rue de la Libération, 75004 Inop-en-Isère
E-mail: gilles.stoltz@ens.fr
URL: <http://www.math.ens.fr/~stoltz>

* L'auteur remercie l'Agence nationale de la recherche pour son soutien à travers le projet JCRC06-137444 ATLAS ("From applications in theory to learning and adaptive statistics").

* Ces recherches ont été menées dans le cadre du projet CLASSIC de l'INRIA, hébergé par l'Ecole normale supérieure et le CNRS.

Journal de la Société Française de Statistique, Vol. 151, No. 2, 66-106
<http://www.afss.asso.fr/journal>
© Société Française de Statistique et Société Mathématique de France (2010) ISSN: 2002-6210