

Exposé et témoignage

Post-doctorante

Journée Maths en Herbe

Margaux Zaffran

21 janvier 2026



- ENSTA Paris (2016-2020)
- M1 Mathématiques Appliquées (2017-2018)
- Année de césure : stages EDF R&D et GE Healthcare
- M2 Data Sciences


- ENSTA Paris (2016-2020)
- M1 Mathématiques Appliquées (2017-2018)
- Année de césure : stages EDF R&D et GE Healthcare
- M2 Data Sciences
- Thèse en statistiques au Centre de Mathématiques Appliquées de l'Ecole polytechnique, à l'Inria et en CIFRE avec EDF R&D (2024)

- ENSTA Paris (2016-2020)
- M1 Mathématiques Appliquées (2017-2018)
- Année de césure : stages EDF R&D et GE Healthcare
- M2 Data Sciences
- Thèse en statistiques au Centre de Mathématiques Appliquées de l'Ecole polytechnique, à l'Inria et en CIFRE avec EDF R&D (2024)
- Post-doctorante à UC Berkeley (2024-2025)

- ENSTA Paris (2016-2020)
- M1 Mathématiques Appliquées (2017-2018)
- Année de césure : stages EDF R&D et GE Healthcare
- M2 Data Sciences
- Thèse en statistiques au Centre de Mathématiques Appliquées de l'Ecole polytechnique, à l'Inria et en CIFRE avec EDF R&D (2024)
- Post-doctorante à UC Berkeley (2024-2025)
- Post-doctorante au Laboratoire de Mathématiques d'Orsay depuis cette année



Illustrations @theoremlinger




Illustrations @theoremlinger




Illustrations @theoremlinger

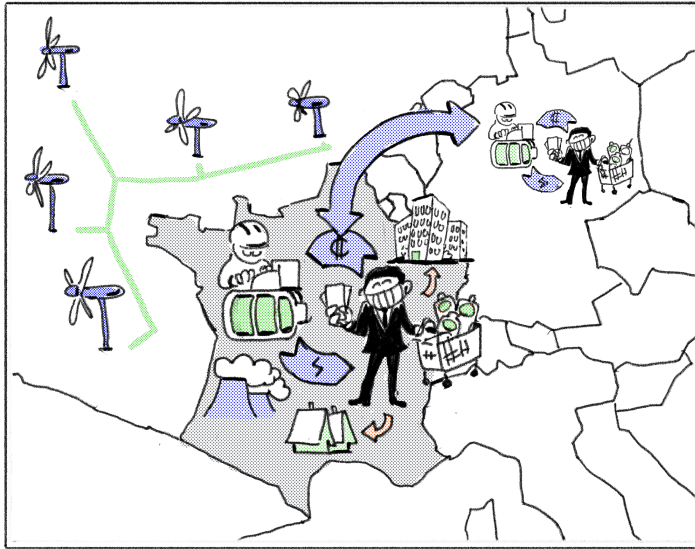
Une situation paradoxale




Vendre et stocker au bon moment !




Mais au fait, à qui vendre ? Et qui vend ?



Prix spot français de l'électricité de 2016 à 2023





Prévoir à partir de variables descriptives

Jour et heure	Prix	Prix J-1	Prix J-7	Conso.	Jour
11/01/16 0PM	21.95	15.58	13.78	58800	Lundi
11/01/16 1PM	20.04	19.05	13.44	57600	Lundi
⋮	⋮	⋮	⋮	⋮	⋮
12/01/16 0PM	21.51	21.95	25.03	61600	Mardi
12/01/16 1PM	19.81	20.04	24.42	59800	Mardi
⋮	⋮	⋮	⋮	⋮	⋮
18/01/16 0PM	38.14	37.86	21.95	70400	Lundi
18/01/16 1PM	35.66	34.60	20.04	69500	Lundi
⋮	⋮	⋮	⋮	⋮	⋮

Prévoir à partir de variables descriptives

Jour et heure	Prix	Prix J-1	Prix J-7	Conso.	Jour
11/01/16 0PM	21.95	15.58	13.78	58800	Lundi
11/01/16 1PM	20.04	19.05	13.44	57600	Lundi
⋮	⋮	⋮	⋮	⋮	⋮
12/01/16 0PM	21.51	21.95	25.03	61600	Mardi
12/01/16 1PM	19.81	20.04	24.42	59800	Mardi
⋮	⋮	⋮	⋮	⋮	⋮
18/01/16 0PM	38.14	37.86	21.95	70400	Lundi
18/01/16 1PM	35.66	34.60	20.04	69500	Lundi
⋮	⋮	⋮	⋮	⋮	⋮

- $y_t \in \mathbb{R}$

Prévoir à partir de variables descriptives

Jour et heure	Prix	Prix J-1	Prix J-7	Conso.	Jour
11/01/16 0PM	21.95	15.58	13.78	58800	Lundi
11/01/16 1PM	20.04	19.05	13.44	57600	Lundi
⋮	⋮	⋮	⋮	⋮	⋮
12/01/16 0PM	21.51	21.95	25.03	61600	Mardi
12/01/16 1PM	19.81	20.04	24.42	59800	Mardi
⋮	⋮	⋮	⋮	⋮	⋮
18/01/16 0PM	38.14	37.86	21.95	70400	Lundi
18/01/16 1PM	35.66	34.60	20.04	69500	Lundi
⋮	⋮	⋮	⋮	⋮	⋮

- $y_t \in \mathbb{R}$

- $\mathbf{x}_t \in \mathbb{R}^d$

$$\rightarrow y_t = f(\mathbf{x}_t) + \varepsilon_t$$

Prévoir à partir de variables descriptives

Jour et heure	Prix	Prix J-1	Prix J-7	Conso.	Jour
11/01/16 0PM	21.95	15.58	13.78	58800	Lundi
11/01/16 1PM	20.04	19.05	13.44	57600	Lundi
⋮	⋮	⋮	⋮	⋮	⋮
12/01/16 0PM	21.51	21.95	25.03	61600	Mardi
12/01/16 1PM	19.81	20.04	24.42	59800	Mardi
⋮	⋮	⋮	⋮	⋮	⋮
18/01/16 0PM	38.14	37.86	21.95	70400	Lundi
18/01/16 1PM	35.66	34.60	20.04	69500	Lundi
⋮	⋮	⋮	⋮	⋮	⋮

- $y_t \in \mathbb{R}$
 - $\mathbf{x}_t \in \mathbb{R}^d$
- $\rightarrow y_t = f(\mathbf{x}_t) + \varepsilon_t$

Ex. : $y_1 = 21.95$ et $\mathbf{x}_1 = (01, 0PM, 15.58, 13.78, 58800, \text{Lundi})$

Utiliser le passé pour évaluer les modèles

	Jour et heure	Prix	Prix J-1	Prix J-7	Conso.	Jour
→	11/01/16 0PM	21.95	15.58	13.78	58800	Lundi
→	11/01/16 1PM	20.04	19.05	13.44	57600	Lundi
	⋮	⋮	⋮	⋮	⋮	⋮
→	12/01/16 0PM	21.51	21.95	25.03	61600	Mardi
→	12/01/16 1PM	19.81	20.04	24.42	59800	Mardi
	⋮	⋮	⋮	⋮	⋮	⋮
→	18/01/16 0PM	38.14	37.86	21.95	70400	Lundi
→	18/01/16 1PM	35.66	34.60	20.04	69500	Lundi
	⋮	⋮	⋮	⋮	⋮	⋮

Utiliser le passé pour évaluer les modèles


	Jour et heure	Prix	Prix J-1	Prix J-7	Conso.	Jour
→	11/01/16 0PM	?	15.58	13.78	58800	Lundi
→	11/01/16 1PM	?	19.05	13.44	57600	Lundi
	⋮	⋮	⋮	⋮	⋮	⋮
→	12/01/16 0PM	?	21.95	25.03	61600	Mardi
→	12/01/16 1PM	?	20.04	24.42	59800	Mardi
	⋮	⋮	⋮	⋮	⋮	⋮
→	18/01/16 0PM	?	37.86	21.95	70400	Lundi
→	18/01/16 1PM	?	34.60	20.04	69500	Lundi
	⋮	⋮	⋮	⋮	⋮	⋮

Utiliser le passé pour évaluer les modèles

	Jour et heure	Prix	Prix J-1	Prix J-7	Conso.	Jour
→	11/01/16 0PM	21.95	15.58	13.78	58800	Lundi
→	11/01/16 1PM	20.04	19.05	13.44	57600	Lundi
	⋮	⋮	⋮	⋮	⋮	⋮
→	12/01/16 0PM	21.51	21.95	25.03	61600	Mardi
→	12/01/16 1PM	19.81	20.04	24.42	59800	Mardi
	⋮	⋮	⋮	⋮	⋮	⋮
→	18/01/16 0PM	38.14	37.86	21.95	70400	Lundi
→	18/01/16 1PM	35.66	34.60	20.04	69500	Lundi
	⋮	⋮	⋮	⋮	⋮	⋮


Évaluer les prédictions d'un modèle

Prix prédit



11/01/2016

Prix prédit



31/12/2019

$$\text{erreur} = \left| \text{prix réel} - \text{prix prédit} \right|$$

Pour chaque modèle ou fonction f , on calcule l'**erreur moyenne empirique** :

$$\text{erreur empirique } (f) = \frac{1}{N} \sum_{i=1}^N \text{erreur de } f \text{ sur l'exemple } i.$$

Pour chaque modèle ou fonction f , on calcule l'**erreur moyenne empirique** :

$$\text{erreur empirique } (f) = \frac{1}{N} \sum_{i=1}^N \text{erreur de } f \text{ sur l'exemple } i.$$

En pratique, on restreint notre recherche à $f \in \mathcal{F}$.

Pour chaque modèle ou fonction f , on calcule l'**erreur moyenne empirique** :

$$\text{erreur empirique}(f) = \frac{1}{N} \sum_{i=1}^N \text{erreur de } f \text{ sur l'exemple } i.$$

En pratique, on restreint notre recherche à $f \in \mathcal{F}$.

Modèle linéaire

$$\mathcal{F} := \left\{ f \text{ telles que } f(\mathbf{x}) = \gamma + \beta^T \mathbf{x}, \right. \\ \left. \text{avec } (\gamma, \beta) \in \mathbb{R} \times \mathbb{R}^d \right\}$$

Trouver la meilleure fonction f parmi un groupe de candidates

Modèle linéaire

$$\mathcal{F} := \left\{ f \text{ telles que } f(\mathbf{x}) = \gamma + \beta^T \mathbf{x}, \right. \\ \left. \text{avec } (\gamma, \beta) \in \mathbb{R} \times \mathbb{R}^d \right\}$$

On cherche donc les **meilleures valeurs de β et γ** pour que f donne des prédictions qui ressemblent au mieux à nos valeurs à prédire.

Trouver la meilleure fonction f parmi un groupe de candidates

Modèle linéaire

$$\mathcal{F} := \left\{ f \text{ telles que } f(\mathbf{x}) = \gamma + \beta^T \mathbf{x}, \right. \\ \left. \text{avec } (\gamma, \beta) \in \mathbb{R} \times \mathbb{R}^d \right\}$$

On cherche donc les **meilleures valeurs de β et γ** pour que f donne des prédictions qui ressemblent au mieux à nos valeurs à prédire.

⇒ On cherche les valeurs de β et γ telles que f donne des prédictions de **plus petite erreur moyenne empirique possible**.

Trouver la meilleure fonction f parmi un groupe de candidates

Modèle linéaire

$$\mathcal{F} := \left\{ f \text{ telles que } f(\mathbf{x}) = \gamma + \beta^T \mathbf{x}, \right. \\ \left. \text{avec } (\gamma, \beta) \in \mathbb{R} \times \mathbb{R}^d \right\}$$

On cherche donc les **meilleures valeurs de β et γ** pour que f donne des prédictions qui ressemblent au mieux à nos valeurs à prédire.

⇒ On cherche les valeurs de β et γ telles que f donne des prédictions de **plus petite erreur moyenne empirique possible**.

$$f^* = \operatorname{argmin}_{f \in \mathcal{F}} \{ \text{erreur empirique}(f) \}$$

Trouver la meilleure fonction f parmi un groupe de candidates

Modèle linéaire

$$\mathcal{F} := \left\{ f \text{ telles que } f(\mathbf{x}) = \gamma + \beta^T \mathbf{x}, \right. \\ \left. \text{avec } (\gamma, \beta) \in \mathbb{R} \times \mathbb{R}^d \right\}$$


On cherche donc les **meilleures valeurs de β et γ** pour que f donne des prédictions qui ressemblent au mieux à nos valeurs à prédire.

\Rightarrow On cherche les valeurs de β et γ telles que f donne des prédictions de **plus petite erreur moyenne empirique possible**.


$$f^* = \operatorname{argmin}_{f \in \mathcal{F}} \{ \text{erreur empirique}(f) \}$$

\hookrightarrow Réseau de neurones $\longrightarrow \mathcal{F}$ plus riche

Qu'est-ce que cela donne sur les prix de l'électricité ?



Qu'est-ce que cela donne sur les prix de l'électricité ?




↪ Les meilleurs modèles de prévision de prix font 10% d'erreur relative


Et la fiabilité dans tout ça ?



Nouvel objectif :




Nouvel objectif :



Quantifier l'incertitude prédictive avec :


Nouvel objectif :



Quantifier l'incertitude prédictive avec :

- Des méthodes théoriquement valides


Nouvel objectif :



Quantifier l'incertitude prédictive avec :

- Des méthodes théoriquement valides
- **Peu d'hypothèses sur la distribution des données**


Nouvel objectif :



Quantifier l'incertitude prédictive avec :

- Des méthodes théoriquement valides
- Peu d'hypothèses sur la distribution des données
- **Des garanties agnostiques au modèle de prédiction**
 - ~> Approche post-hoc (i.e. s'encapsuler en bout de chaîne autour de n'importe quel algorithme opérationnel pré-existant)

Nouvel objectif :



Quantifier l'incertitude prédictive avec :

- Des méthodes théoriquement valides
- Peu d'hypothèses sur la distribution des données
- **Des garanties agnostiques au modèle de prédiction**
 - ~> **Approche post-hoc** (i.e. s'encapsuler en bout de chaîne autour de n'importe quel algorithme opérationnel pré-existant)

L'utilisateur choisit un **niveau de confiance** $1 - \alpha$.

Par exemple 0.9 (autrement dit 90%) correspond à $\alpha = 0.1$.

L'utilisateur choisit un **niveau de confiance** $1 - \alpha$.

Par exemple 0.9 (autrement dit 90%) correspond à $\alpha = 0.1$.

Notons $\mathcal{C}_\alpha(x)$ une région prédictive de niveau $1 - \alpha$ en un point x .

L'utilisateur choisit un **niveau de confiance** $1 - \alpha$.

Par exemple 0.9 (autrement dit 90%) correspond à $\alpha = 0.1$.


Notons $\mathcal{C}_\alpha(x)$ une région prédictive de niveau $1 - \alpha$ en un point x .

Celle-ci doit vérifier la propriété suivante :

$$\mathbb{P} \{ Y \in \mathcal{C}_\alpha(X) \} \geq 1 - \alpha,$$

tout en étant la plus petite possible.

Prédictions conformes par partition^{1,2,3} : phase d'entraînement




► Apprendre f

¹?, *Algorithmic Learning in a Random World*

²?, *Inductive Confidence Machines for Regression*, ECML

³?, *Distribution-Free Predictive Inference for Regression*, JRSS B

Prédictions conformes par partition^{1,2,3} : phase de calibration




► Prédire avec f

¹?, *Algorithmic Learning in a Random World*

²?, *Inductive Confidence Machines for Regression*, ECML

³?, *Distribution-Free Predictive Inference for Regression*, JRSS B

Prédictions conformes par partition^{1,2,3} : phase de calibration




- Prédire avec f
- Obtenir les erreurs

¹?, *Algorithmic Learning in a Random World*

²?, *Inductive Confidence Machines for Regression*, ECML

³?, *Distribution-Free Predictive Inference for Regression*, JRSS B

Prédictions conformes par partition^{1,2,3} : phase de calibration




- Prédire avec f
- Obtenir les erreurs
- Trouver le quantile de niveau 0.9 de ces erreurs (la $0.9 \times n$ -ème plus grande erreur), notée $q_{0.9}$ (erreurs)

¹?, *Algorithmic Learning in a Random World*

²?, *Inductive Confidence Machines for Regression*, ECML

³?, *Distribution-Free Predictive Inference for Regression*, JRSS B

Prédictions conformes par partition^{1,2,3} : phase de prédiction




► Prédire avec f

¹?, *Algorithmic Learning in a Random World*

²?, *Inductive Confidence Machines for Regression*, ECML

³?, *Distribution-Free Predictive Inference for Regression*, JRSS B

Prédictions conformes par partition^{1,2,3} : phase de prédiction



► Prédire avec f

► Construire $\mathcal{C}(x)$:

$$[f(x) - q_{0.9}(\text{erreurs});$$


$$f(x) + q_{0.9}(\text{erreurs})]$$


¹?, *Algorithmic Learning in a Random World*

²?, *Inductive Confidence Machines for Regression*, ECML

³?, *Distribution-Free Predictive Inference for Regression*, JRSS B

Revenons-en aux prix de l'électricité





- Phénomènes temporels (cycles, tendances, dépendance aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes.

- Phénomènes temporels (cycles, tendances, dépendance aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes. **Extension de la méthode aux séries temporelles.**

- Phénomènes temporels (cycles, tendances, dépendance aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes. **Extension de la méthode aux séries temporelles.**
- La garantie n'est qu'en moyenne. La méthode fait plus d'erreurs sur les week-ends que la semaine par exemple.

- Phénomènes temporels (cycles, tendances, dépendance aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes. **Extension de la méthode aux séries temporelles.**
- La garantie n'est qu'en moyenne. La méthode fait plus d'erreurs sur les week-ends que la semaine par exemple.

$$\mathbb{P}(Y \in \mathcal{C}_{1-\alpha}(X) | X = x) \geq 1 - \alpha$$

- Phénomènes temporels (cycles, tendances, dépendance aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes. **Extension de la méthode aux séries temporelles.**
- La garantie n'est qu'en moyenne. La méthode fait plus d'erreurs sur les week-ends que la semaine par exemple.

$$\mathbb{P}(Y \in \mathcal{C}_{1-\alpha}(X) | \textcolor{brown}{X} = \textcolor{brown}{x}) \geq 1 - \alpha$$

- Phénomènes temporels (cycles, tendances, dépendance aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes. **Extension de la méthode aux séries temporelles.**
- La garantie n'est qu'en moyenne. La méthode fait plus d'erreurs sur les week-ends que la semaine par exemple.

$$\mathbb{P}(Y \in \mathcal{C}_{1-\alpha}(X) | \cancel{X} = x) \geq 1 - \alpha$$

Obtention de garanties plus conditionnelles.

- Phénomènes temporels (cycles, tendances, dépendence aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes. **Extension de la méthode aux séries temporelles.**
- La garantie n'est qu'en moyenne. La méthode fait plus d'erreurs sur les week-ends que la semaine par exemple.

$$\mathbb{P}(Y \in \mathcal{C}_{1-\alpha}(X) | X = x) \geq 1 - \alpha$$

Obtention de garanties plus conditionnelles.

- Que se passe-t-il en présence de données manquantes ? Le modèle de prévision de consommation n'a pas pu prédire (panne de courant par ex.) mais nous voulons quand même prédire le prix.

- Phénomènes temporels (cycles, tendances, dépendence aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes. **Extension de la méthode aux séries temporelles.**
- La garantie n'est qu'en moyenne. La méthode fait plus d'erreurs sur les week-ends que la semaine par exemple.

$$\mathbb{P}(Y \in \mathcal{C}_{1-\alpha}(X) | X = x) \geq 1 - \alpha$$

Obtention de garanties plus conditionnelles.

- Que se passe-t-il en présence de données manquantes ? Le modèle de prévision de consommation n'a pas pu prédire (panne de courant par ex.) mais nous voulons quand même prédire le prix. **Quantification d'incertitudes en présence de données manquantes.**

- Les mathématiques peuvent permettre de faire des prédictions

- Les mathématiques peuvent permettre de faire des prédictions
- Applicable pour de nombreux problèmes réels

- Les mathématiques peuvent permettre de faire des prédictions
- Applicable pour de nombreux problèmes réels
- Ne jamais interpréter des prédictions ponctuelles

- Les mathématiques peuvent permettre de faire des prédictions
- Applicable pour de nombreux problèmes réels
- Ne jamais interpréter des prédictions ponctuelles
- Offrir des garanties aux citoyens

- Les mathématiques peuvent permettre de faire des prédictions
- Applicable pour de nombreux problèmes réels
- Ne jamais interpréter des prédictions ponctuelles
- Offrir des garanties aux citoyens
- Transversalité et universalité des mathématiques

