

# Rendre moins incertain l'avenir des énergies renouvelables

---

Margaux Zaffran

5 janvier 2023



# Mes directeurs de thèse



**Aymeric  
Dieuleveut**

Ecole  
Polytechnique  
*Paris*



**Olivier Féron**

EDF R&D  
FiME  
*Paris*



**Yannig Goude**

EDF R&D  
LMO  
*Paris*




**Julie Josse**

INRIA  
IDESP  
*Montpellier*


# Un petit coup au moral...




# Électrification, électrification renouvelable




# Électrification, électrification renouvelable




# Électrification, électrification renouvelable




# Une situation paradoxale




# Vendre et stocker au bon moment !




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



# Visualisation des prix spot français de l'électricité




# Visualisation des prix spot français de l'électricité



axe des y : prix, axe des x : temps

# Visualisation des prix spot français de l'électricité




axe des y : prix (en rouge gaz), axe des x : temps


**Essayons de prévoir les prix de l'électricité**

---


# Objectif de prévision




## Objectif de prévision




# Objectif de prévision




# Objectif de prévision



# Objectif de prévision



# Objectif de prévision



## Une première modélisation

Jour et heure	Prix	Prix J-1	Prix J-7
11/01/16 0PM	21.95	15.58	13.78
11/01/16 1PM	20.04	19.05	13.44
⋮	⋮	⋮	⋮
12/01/16 0PM	21.51	21.95	25.03
12/01/16 1PM	19.81	20.04	24.42
⋮	⋮	⋮	⋮
18/01/16 0PM	38.14	37.86	21.95
18/01/16 1PM	35.66	34.60	20.04
⋮	⋮	⋮	⋮

## Une première modélisation

Jour et heure	Prix	Prix J-1	Prix J-7
11/01/16 0PM	<b>21.95</b>	15.58	13.78
11/01/16 1PM	<b>20.04</b>	19.05	13.44
⋮	⋮	⋮	⋮
12/01/16 0PM	<b>21.51</b>	21.95	25.03
12/01/16 1PM	<b>19.81</b>	20.04	24.42
⋮	⋮	⋮	⋮
18/01/16 0PM	<b>38.14</b>	37.86	21.95
18/01/16 1PM	<b>35.66</b>	34.60	20.04
⋮	⋮	⋮	⋮


## Une première modélisation

Jour et heure	Prix	Prix J-1	Prix J-7
11/01/16 0PM	21.95	15.58	13.78
11/01/16 1PM	20.04	19.05	13.44
⋮	⋮	⋮	⋮
12/01/16 0PM	21.51	21.95	25.03
12/01/16 1PM	19.81	20.04	24.42
⋮	⋮	⋮	⋮
18/01/16 0PM	38.14	37.86	21.95
18/01/16 1PM	35.66	34.60	20.04
⋮	⋮	⋮	⋮

$$\rightarrow \text{Prix} = f(\text{Prix J} - 1, \text{Prix J} - 7) + \varepsilon$$

## Des exemples de modèles




$$\begin{aligned}\text{Prix pr\u00e9dit} &\approx f(\text{Prix J-1}, \text{Prix J-7}) \\ &= \text{Prix J-1}\end{aligned}$$



# Des exemples de modèles

$$\text{Prix pr\u00e9dit} \approx f(\text{Prix J-1}, \text{Prix J-7})$$


$$= \frac{\text{Prix J-1} + \text{Prix J-7}}{2}$$



## Des exemples de modèles

$$\text{Prix pr\u00e9dit} \approx f(\text{Prix J-1}, \text{Prix J-7})$$

$$= 0.75 \times \text{Prix J-1} + 0.25 \times \text{Prix J-7}$$



## Utiliser le passé pour évaluer les modèles

	Jour et heure	Prix	Prix J-1	Prix J-7
→	11/01/16 0PM	<b>21.95</b>	15.58	13.78
→	11/01/16 1PM	<b>20.04</b>	19.05	13.44
	⋮	⋮	⋮	⋮
→	12/01/16 0PM	<b>21.51</b>	21.95	25.03
→	12/01/16 1PM	<b>19.81</b>	20.04	24.42
	⋮	⋮	⋮	⋮
→	18/01/16 0PM	<b>38.14</b>	37.86	21.95
→	18/01/16 1PM	<b>35.66</b>	34.60	20.04
	⋮	⋮	⋮	⋮



## Utiliser le passé pour évaluer les modèles

	Jour et heure	Prix	Prix J-1	Prix J-7
→	11/01/16 0PM	?	15.58	13.78
→	11/01/16 1PM	?	19.05	13.44
	⋮	⋮	⋮	⋮
→	12/01/16 0PM	?	21.95	25.03
→	12/01/16 1PM	?	20.04	24.42
	⋮	⋮	⋮	⋮
→	18/01/16 0PM	?	37.86	21.95
→	18/01/16 1PM	?	34.60	20.04
	⋮	⋮	⋮	⋮

## Utiliser le passé pour évaluer les modèles

	Jour et heure	Prix	Prix J-1	Prix J-7
→	11/01/16 0PM	<b>21.95</b>	15.58	13.78
→	11/01/16 1PM	<b>20.04</b>	19.05	13.44
	⋮	⋮	⋮	⋮
→	12/01/16 0PM	<b>21.51</b>	21.95	25.03
→	12/01/16 1PM	<b>19.81</b>	20.04	24.42
	⋮	⋮	⋮	⋮
→	18/01/16 0PM	<b>38.14</b>	37.86	21.95
→	18/01/16 1PM	<b>35.66</b>	34.60	20.04
	⋮	⋮	⋮	⋮

# Évaluer les prédictions d'un modèle



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

## Évaluer les fonctions $f$ d'un groupe de candidates

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

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

## Évaluer les fonctions $f$ d'un groupe de candidates

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

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

Impossible de tester toutes les fonctions  $f$  possibles.

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

# Évaluer les fonctions $f$ d'un groupe de candidates

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

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

Impossible de tester toutes les fonctions  $f$  possibles.

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

## Exemple (modèle linéaire)

$\mathcal{F} := \{ f \text{ telles que}$

$$f(\text{Prix } J-1, \text{Prix } J-7) = \beta \times \text{Prix } J-1 + \delta \times \text{Prix } J-7 + \gamma,$$

avec  $(\beta, \delta, \gamma) \in \mathbb{R}^3 \}$


## Exemple (modèle linéaire)

$\mathcal{F} := \{ f \text{ telles que}$

$$f(\text{Prix } J-1, \text{Prix } J-7) = \beta \times \text{Prix } J-1 + \delta \times \text{Prix } J-7 + \gamma, \\ \text{avec } (\beta, \delta, \gamma) \in \mathbb{R}^3 \}$$

Si  $\beta = 1$  et  $\delta = 0, \gamma = 0$  on retrouve la première fonction  $f$ .

$$\begin{aligned} \text{Prix prédit} &\approx f(\text{Prix } J-1, \text{Prix } J-7) \\ &= \text{Prix } J-1 \end{aligned}$$




## Exemple (modèle linéaire)

$\mathcal{F} := \{ f \text{ telles que}$

$$f(\text{Prix } J-1, \text{Prix } J-7) = \beta \times \text{Prix } J-1 + \delta \times \text{Prix } J-7 + \gamma, \\ \text{avec } (\beta, \delta, \gamma) \in \mathbb{R}^3 \}$$

Si  $\beta = \delta = 0.5$  et  $\gamma = 0$  on retrouve la deuxième fonction  $f$ .




## Exemple (modèle linéaire)

$\mathcal{F} := \{ f \text{ telles que}$

$$f(\text{Prix } J-1, \text{Prix } J-7) = \beta \times \text{Prix } J-1 + \delta \times \text{Prix } J-7 + \gamma, \\ \text{avec } (\beta, \delta, \gamma) \in \mathbb{R}^3 \}$$

Si  $\beta = 0.75$ ,  $\delta = 0.25$  et  $\gamma = 0$  on retrouve la troisième fonction  $f$ .



# Trouver la meilleure fonction $f$ parmi un groupe de candidates

## Exemple (modèle linéaire)

$\mathcal{F} := \{ f \text{ telles que}$

$$f(\text{Prix } J-1, \text{Prix } J-7) = \beta \times \text{Prix } J-1 + \delta \times \text{Prix } J-7 + \gamma,$$

avec  $(\beta, \delta, \gamma) \in \mathbb{R}^3 \}$

On cherche donc les **meilleures valeurs de  $\beta$ ,  $\delta$  et  $\gamma$**  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

## Exemple (modèle linéaire)

$\mathcal{F} := \{ f \text{ telles que}$

$$f(\text{Prix } J-1, \text{Prix } J-7) = \beta \times \text{Prix } J-1 + \delta \times \text{Prix } J-7 + \gamma,$$

avec  $(\beta, \delta, \gamma) \in \mathbb{R}^3 \}$

On cherche donc les **meilleures valeurs de  $\beta$ ,  $\delta$  et  $\gamma$**  pour que  $f$  donne des prédictions qui ressemblent au mieux à nos valeurs à prédire.

$\Rightarrow$  On cherche les valeurs de  $\beta$ ,  $\delta$  et  $\gamma$  telles que  $f$  donne des prédictions de **plus petite erreur moyenne empirique possible**.

# Trouver la meilleure fonction $f$ parmi un groupe de candidates

## Exemple (modèle linéaire)

$\mathcal{F} := \{ f \text{ telles que}$

$$f(\text{Prix } J-1, \text{Prix } J-7) = \beta \times \text{Prix } J-1 + \delta \times \text{Prix } J-7 + \gamma,$$

avec  $(\beta, \delta, \gamma) \in \mathbb{R}^3 \}$

On cherche donc les **meilleures valeurs de  $\beta$ ,  $\delta$  et  $\gamma$**  pour que  $f$  donne des prédictions qui ressemblent au mieux à nos valeurs à prédire.

$\Rightarrow$  On cherche les valeurs de  $\beta$ ,  $\delta$  et  $\gamma$  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

## Exemple (modèle linéaire)

$\mathcal{F} := \{ f \text{ telles que}$

$$f(\text{Prix } J-1, \text{Prix } J-7) = \beta \times \text{Prix } J-1 + \delta \times \text{Prix } J-7 + \gamma,$$

avec  $(\beta, \delta, \gamma) \in \mathbb{R}^3 \}$

On cherche donc les **meilleures valeurs de  $\beta$ ,  $\delta$  et  $\gamma$**  pour que  $f$  donne des prédictions qui ressemblent au mieux à nos valeurs à prédire.

$\Rightarrow$  On cherche les valeurs de  $\beta$ ,  $\delta$  et  $\gamma$  telles que  $f$  donne des prédictions de **plus petite erreur moyenne empirique possible**.

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

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

## Intégrer plus d'informations

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
⋮	⋮	⋮	⋮	⋮	⋮

## Intégrer plus d'informations

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

- $y_t \in \mathbb{R}$

## Intégrer plus d'informations

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
⋮	⋮	⋮	⋮	⋮	⋮

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


## Intégrer plus d'informations

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
⋮	⋮	⋮	⋮	⋮	⋮

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

Ex. :  $y_1 = 21.95$  et  $x_1 = (01, 0PM, 15.58, 13.78, 58800, \text{Lundi})$

## Voilà notre prévision



# Et la fiabilité dans tout ça ?



**Peut-on créer un indicateur de confiance  
des modèles ?**

---

## De l'importance des régions prédictives


- “Demain, il fera  $20^{\circ} \pm 1^{\circ}$ ” versus “Demain, il fera  $20^{\circ} \pm 10^{\circ}$ ”

## De l'importance des régions prédictives

- “Demain, il fera  $20^{\circ} \pm 1^{\circ}$ ” versus “Demain, il fera  $20^{\circ} \pm 10^{\circ}$ ”
- “Si vous prenez 1g de ce médicament, votre pression sanguine sera de  $125 \pm 5$ ” versus “Si vous prenez 1g de ce médicament, votre pression sanguine sera de  $125 \pm 30$ ”

## De l'importance des régions prédictives

- “Demain, il fera  $20^{\circ} \pm 1^{\circ}$ ” versus “Demain, il fera  $20^{\circ} \pm 10^{\circ}$ ”
- “Si vous prenez 1g de ce médicament, votre pression sanguine sera de  $125 \pm 5$ ” versus “Si vous prenez 1g de ce médicament, votre pression sanguine sera de  $125 \pm 30$ ”
- Dans notre cas, on cherche à construire de tels intervalles :



## Les objectifs d'une région prédictive

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

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

## Les objectifs d'une région prédictive

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

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

Notons  $\mathcal{C}_{0.9}(x)$  une région prédictive de niveau 90% en un point  $x$ .

## Les objectifs d'une région prédictive

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

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


Notons  $\mathcal{C}_{0.9}(x)$  une région prédictive de niveau 90% en un point  $x$ .

Celle-ci doit vérifier la propriété suivante :

$$\mathbb{P}(Y \in \mathcal{C}_{0.9}(X)) \geq 0.9,$$

tout en étant la plus petite possible.

# Prédictions conformes par partition<sup>1,2,3</sup> : phase d'entraînement



► Apprendre  $f$


---

<sup>1</sup>Vovk et al. (2005), *Algorithmic Learning in a Random World*

<sup>2</sup>Papadopoulos et al. (2002), *Inductive Confidence Machines for Regression*, ECML

<sup>3</sup>Lei et al. (2018), *Distribution-Free Predictive Inference for Regression*, JRSS B

# Prédictions conformes par partition<sup>1,2,3</sup> : phase de calibration




► Prédire avec  $f$

<sup>1</sup>Vovk et al. (2005), *Algorithmic Learning in a Random World*

<sup>2</sup>Papadopoulos et al. (2002), *Inductive Confidence Machines for Regression*, ECML

<sup>3</sup>Lei et al. (2018), *Distribution-Free Predictive Inference for Regression*, JRSS B

# Prédictions conformes par partition<sup>1,2,3</sup> : phase de calibration




- ▶ Prédire avec  $f$
- ▶ Obtenir les erreurs

<sup>1</sup>Vovk et al. (2005), *Algorithmic Learning in a Random World*

<sup>2</sup>Papadopoulos et al. (2002), *Inductive Confidence Machines for Regression*, ECML

<sup>3</sup>Lei et al. (2018), *Distribution-Free Predictive Inference for Regression*, JRSS B

# Prédictions conformes par partition<sup>1,2,3</sup> : phase de calibration




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

<sup>1</sup>Vovk et al. (2005), *Algorithmic Learning in a Random World*

<sup>2</sup>Papadopoulos et al. (2002), *Inductive Confidence Machines for Regression*, ECML

<sup>3</sup>Lei et al. (2018), *Distribution-Free Predictive Inference for Regression*, JRSS B

# Prédictions conformes par partition<sup>1,2,3</sup> : phase de prédiction




► Prédire avec  $f$

<sup>1</sup>Vovk et al. (2005), *Algorithmic Learning in a Random World*

<sup>2</sup>Papadopoulos et al. (2002), *Inductive Confidence Machines for Regression*, ECML

<sup>3</sup>Lei et al. (2018), *Distribution-Free Predictive Inference for Regression*, JRSS B

# Prédictions conformes par partition<sup>1,2,3</sup> : phase de prédiction



► Prédire avec  $f$

► Construire  $\mathcal{C}(x)$ :


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

<sup>1</sup>Vovk et al. (2005), *Algorithmic Learning in a Random World*

<sup>2</sup>Papadopoulos et al. (2002), *Inductive Confidence Machines for Regression*, ECML

<sup>3</sup>Lei et al. (2018), *Distribution-Free Predictive Inference for Regression*, JRSS B

## Revenons-en aux prix de l'électricité



## Conclusion

---

## Des idées (biaisées) d'approfondissement

- 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** (Zaffran et al., 2022).

- Phénomènes temporels (cycles, tendances, dépendance aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes. **Extension de la méthode aux séries temporelles** (Zaffran et al., 2022).
- La garantie n'est qu'en moyenne. La méthode fait plus d'erreurs sur les week-ends que la semaine par exemple.

## Des idées (biaisées) d'approfondissement

- Phénomènes temporels (cycles, tendances, dépendance aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes. **Extension de la méthode aux séries temporelles** (Zaffran et al., 2022).
- La garantie n'est qu'en moyenne. La méthode fait plus d'erreurs sur les week-ends que la semaine par exemple.

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

## Des idées (biaisées) d'approfondissement

- Phénomènes temporels (cycles, tendances, dépendance aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes. **Extension de la méthode aux séries temporelles** (Zaffran et al., 2022).
- La garantie n'est qu'en moyenne. La méthode fait plus d'erreurs sur les week-ends que la semaine par exemple.

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

## Des idées (biaisées) d'approfondissement

- Phénomènes temporels (cycles, tendances, dépendance aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes. **Extension de la méthode aux séries temporelles** (Zaffran et al., 2022).
- 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.**

## Des idées (biaisées) d'approfondissement

- Phénomènes temporels (cycles, tendances, dépendance aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes. **Extension de la méthode aux séries temporelles** (Zaffran et al., 2022).
- 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.

## Des idées (biaisées) d'approfondissement

- Phénomènes temporels (cycles, tendances, dépendance aux jours d'avant ...) mettent en défaut l'hypothèse des prédictions conformes. **Extension de la méthode aux séries temporelles** (Zaffran et al., 2022).
- 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** (présentation suivante).

- Les mathématiques peuvent permettre de faire des prédictions

## Messages à retenir

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

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

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

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

## Références

- Lei, J., G'Sell, M., Rinaldo, A., Tibshirani, R. J., and Wasserman, L. (2018). Distribution-Free Predictive Inference for Regression. *Journal of the American Statistical Association*.
- Papadopoulos, H., Proedrou, K., Vovk, V., and Gammerman, A. (2002). Inductive Confidence Machines for Regression. In *Machine Learning: ECML 2002*. Springer.
- Vovk, V., Gammerman, A., and Shafer, G. (2005). *Algorithmic Learning in a Random World*. Springer US.
- Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International Journal of Forecasting*, 30(4).
- Zaffran, M., Féron, O., Goude, Y., Josse, J., and Dieuleveut, A. (2022). Adaptive conformal predictions for time series. In *Proceedings of the 39th International Conference on Machine Learning*. PMLR.