

# Modèles de Fondation et Ajustement : Vers une Nouvelle Génération de Modèles pour la Prévision des Séries Temporelles

Morad Laglil \*, Emilie Devijver \*\*  
Eric Gaussier \*\* Bertrand Pracca\*\*\*

\*,\*\* IMAG 700 Av. Centrale 38058 Saint Martin d'Hères, France  
 morad.laglil@univ-grenoble-alpes.fr,  
 emilie.devijver@univ-grenoble-alpes.fr  
 Eric.Gaussier@imag.fr  
 \*\*\*SAVOYE SASU - Saint-Etienne  
 bertrand.pracca@savoye.com

**Résumé.** Motivés par les récents progrès des grands modèles en traitement automatique du langage naturel, des modèles de fondation ont été développés pour la prévision de séries temporelles en zero-shot, c'est-à-dire sur des jeux de données jamais observés lors du pré-entraînement. Ces modèles, dotés de centaines de millions de paramètres, sont pré-entraînés sur de vastes ensembles de séries temporelles afin d'apprendre des représentations généralisables couvrant la prévision ponctuelle et probabiliste. Ils réduisent ainsi la nécessité de concevoir des modèles spécifiques et d'effectuer un réglage manuel pour chaque tâche.

Dans ce travail, nous présentons un état de l'art des principales architectures et stratégies de pré-entraînement utilisées dans ces modèles, ainsi que leurs méthodes d'optimisation. Nous étudions également l'ajustement de certains modèles de fondation après pré-entraînement, afin d'améliorer leurs performances sur des jeux de données spécifiques. Nos résultats empiriques montrent que cette étape améliore globalement les capacités de prévision en zero-shot.

## 1 Introduction

La prévision de séries temporelles est depuis longtemps une tâche fondamentale pour l'industrie, car elle soutient la prise de décision et l'optimisation des processus dans des domaines aussi variés que l'énergie, les transports, la météorologie, l'économie ou encore la distribution. Ce champ constitue également un axe de recherche académique majeur, ayant conduit à de nombreux progrès visant à améliorer la précision des prévisions.

Les approches traditionnelles de prévision reposent principalement sur des modèles paramétriques conçus à partir de l'expertise métier, tels que les modèles autorégressifs (AR, Box et al. (2015)) ou les méthodes de lissage exponentiel (Gardner, 2006). À l'inverse, les approches modernes d'apprentissage automatique — et plus particulièrement l'apprentissage

## Modèles de fondation pour la prévision des séries temporelles

profond — offrent la capacité de modéliser des dynamiques temporelles complexes en apprenant directement à partir des données, sans hypothèses fortes sur leur distribution. Divers modèles, tels que les forêts aléatoires (Dudek, 2022) et les réseaux de neurones profonds (Salinas et al., 2020), ont ainsi été développés pour améliorer la précision des prévisions et mieux capturer la diversité des comportements temporels observés dans les séries réelles.

Très récemment, les grands modèles de fondation, pré-entraînés sur d'importants volumes de données, se sont imposés comme une avancée majeure dans la prévision de séries temporelles. Bénéficiant de la disponibilité croissante des données et de la puissance de calcul, ces modèles exploitent des biais inductifs reflétant les propriétés structurelles des séries temporelles afin d'apprendre des représentations généralisables. Cette capacité leur permet de s'adapter à une grande variété de contextes, y compris à des situations inédites (zero-shot). Inspirés des succès observés dans le traitement automatique du langage, ces modèles peuvent également être ajustés (fine-tuned) sur des jeux de données spécifiques, permettant ainsi de transférer et de spécialiser les connaissances acquises lors du pré-entraînement. Toutefois, cette question d'ajustement demeure très peu explorée dans la littérature sur les modèles de fondation pour la prévision. Dans cet article, nous nous concentrerons sur deux axes principaux :

- un état de l'art des modèles de fondation pour la prévision de séries temporelles.
- une étude expérimentale de l'ajustement de certains modèles sur un large éventail de jeux de données couvrant différents domaines, fréquences et horizons de prévision. A notre connaissance, il s'agit de la première étude d'ajustement de cette envergure.

Le plan de ce papier est le suivant. Dans la Section 2, nous formalisons le problème de prévision des séries temporelles. La Section 3 présente un état de l'art détaillé, la Section 4 expose les résultats des expériences sur l'ajustement, et la Section 5 discute certains défis avant de conclure.

## 2 Problème de prévision des séries temporelles

La prévision des séries temporelles consiste à prédire les valeurs futures d'une série indexée par le temps à partir des observations passées et d'autres variables exogènes. Formellement, soit  $y_t \in \mathbb{R}^D$  le vecteur d'observations à l'instant  $t$ , et considérons une série temporelle, notée  $\{y_t\}_{t=1}^T$ . La tâche de prévision consiste à estimer les valeurs futures  $\{y_{T+1}, \dots, y_{T+H}\}$  pour un horizon  $H > 0$ , à partir des observations passées (contexte)  $\{y_1, \dots, y_T\}$  et, éventuellement, de  $n_{\text{cov}}$  covariables externes  $\{z_1, \dots, z_T\}$ .

Nous définissons la fonction de prévision comme une application :

$$\begin{aligned} f : \mathbb{R}^{T \times D} \times \mathbb{R}^{T \times n_{\text{cov}}} &\longrightarrow \mathbb{R}^{H \times D} \\ (\{y_t\}_{t=1}^T, \{z_t\}_{t=1}^T) &\mapsto \{y_{T+1}, \dots, y_{T+H}\}. \end{aligned}$$

Dans le cas d'une prévision probabiliste, la tâche consiste simplement à prédire des quantiles de la distribution future au lieu d'une valeur unique.

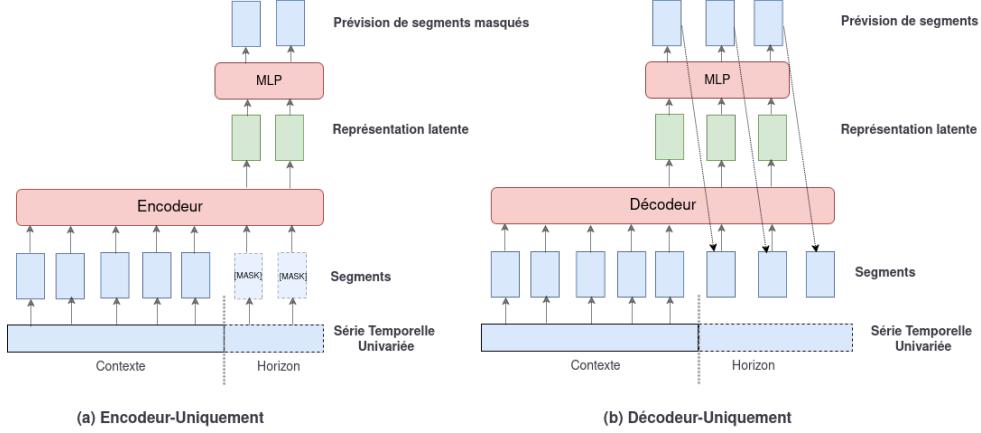


FIG. 1 – Illustration des styles d’architectures : (a) encodeur uniquement avec masquage et (b) décodeur uniquement, avec structure autorégressive. En bleu : la série temporelle d’entrée et ses segments, en rouge : les couches neuronales, et en vert : les représentations latentes des segments. MLP désigne les couches neuronales linéaires utilisées pour générer la prévision à partir des représentations latentes.

### 3 Modèles de fondation pour la prévision des séries temporelles

Dans cette section, nous présentons l’état de l’art relatif à ces modèles, en mettant l’accent sur trois composantes clés : l’**architecture** (Section 3.1), qui définit la structure du réseau et la technologie sous-jacente ; le **pré-entraînement** (Section 3.2), qui consiste à exposer le modèle à de vastes ensembles de données via un apprentissage auto-supervisé ; et l’**adaptation** (Section 3.3), qui regroupe les différentes stratégies d’ajustement. Ces trois dimensions constituent un cadre d’analyse uniifié, permettant à la fois de comparer, classer et mettre en œuvre les modèles de fondation de prévision. Pour décrire ces modèles, nous nous appuierons sur la Figure 1, qui illustre les blocs clés des architectures neuronales classiques. Nous détaillons plusieurs modèles, présentés de façon chronologique, ayant obtenu les meilleures performances sur le benchmark *GIFT-Eval* (Aksu et al., 2024) et illustrant une diversité d’approches selon les trois composantes précédemment décrites.

#### 3.1 Architecture

##### 3.1.1 Modèles basés sur les Transformers

La majorité des modèles de fondation pour la prévision des séries temporelles repose sur l’architecture **Transformer** (Vaswani et al., 2017), un type de modèle initialement conçu pour le traitement du langage naturel. Leur principale innovation réside dans le **mécanisme d’attention**, qui permet au modèle d’accorder une importance variable aux différentes parties de la séquence d’entrée. Ce mécanisme offre la capacité d’apprendre des dépendances à longue

## Modèles de fondation pour la prévision des séries temporelles

portée entre les éléments de la série, ce que les architectures précédentes, comme les réseaux récurrents, peinaient à faire.

Ansari et al. (2024) ont développé un modèle appelé **Chronos**, basé sur une architecture Transformer de type *encodeur-décodeur* (combinant les deux architectures de la Figure 1). L'encodeur analyse la série temporelle passée pour en extraire des représentations riches, tandis que le décodeur génère les prévisions de manière *autoregressive* à partir de ces représentations. Ce modèle reprend les principes du traitement de texte, mais introduit une idée originale : la représentation des séries temporelles sous forme de jetons. Concrètement, chaque valeur de la série est convertie en un jeton correspondant à l'intervalle prédéfini auquel elle appartient. À la sortie, les jetons prédits par le modèle sont reconvertis en valeurs réelles, par exemple en leur associant la borne inférieure de l'intervalle correspondant. Une limite de cette approche est que la plage de prédition reste fixe, car les intervalles sont prédéfinis, ce qui la rend moins adaptée aux séries temporelles présentant des tendances fortes.

Une autre approche pour convertir une série temporelle en unités d'information (ou jetons) exploitables par les Transformers consiste à la segmenter en plusieurs sous-séquences de taille fixe, appelées segments. En divisant les longues séries temporelles en segments plus courts, le modèle devient capable de mieux capturer les motifs locaux au sein de la séquence, améliorant ainsi sa compréhension des dynamiques complexes qu'elle renferme. De plus, cette segmentation contribue à réduire la complexité du modèle Transformer en diminuant le nombre total de jetons à traiter. Das et al. (2024) ont appliqué cette idée dans le modèle **TimesFM**, basé sur une architecture Transformer de type *décodeur-uniquement* (Figure 1(b); dans ce cas, le décodeur est un Transformer). Ce dernier repose sur un mécanisme d'attention causale, où chaque segment ne peut accéder qu'aux segments précédents, sans jamais utiliser d'informations futures. Ainsi, le modèle apprend à effectuer des prévisions en extrayant uniquement les dépendances pertinentes issues du passé. Le modèle adopte un schéma de génération *autoregressive* lors de l'inférence, produisant successivement les segments de sortie. La taille des segments prédits est supérieure à celle des segments d'entrée, ce qui permet d'assurer une prévision à long terme tout en réduisant le nombre d'itérations nécessaires. Cette conception s'appuie sur des travaux antérieurs (Zeng et al., 2023), qui ont montré que la prévision de l'ensemble de l'horizon en une seule étape à partir du passé offre généralement une meilleure précision que les approches autoregressives itératives sur ces modèles.

**Moirai** (Woo et al., 2024) reprend le principe de segmentation des séries temporelles, mais introduit cette fois une taille de segment variable : plus grande pour les séries à haute fréquence (par exemple à la seconde ou à la minute) afin de réduire le coût quadratique de l'attention, plus petite pour les séries à basse fréquence (jour, mois) pour mieux exploiter la capacité de représentation des Transformers. Pour cela, Moirai apprend plusieurs couches de projection d'entrée et de sortie associées à différentes tailles de segments, la sélection manuelle de la taille appropriée dépendant des caractéristiques fréquentielles de la série.

Le cœur du modèle repose sur un Transformer à encodeur uniquement (Figure 1(a), dans ce cas l'encodeur est un Transformer), utilisant une technique de masquage : un jeton fictif [mask] remplace les segments situés dans l'horizon de prévision. Ce jeton possède sa propre représentation apprenable, qui est ensuite décodée via une projection de sortie pour générer la prévision correspondante, ce qui permet d'éviter l'autoregressivité lors de l'inférence.

Un autre défi pour les modèles de fondation en prévision réside dans leur difficulté à traiter des séries temporelles multivariées de dimensions arbitraires. La plupart des Transformers exis-

tants supposent une indépendance entre les variables, car le nombre de dimensions peut varier et n'est pas connu à l'avance. Pour surmonter cette limitation, Moirai adopte une approche consistante à aplatiser la série multivariée afin de la traiter comme une séquence unique. Cette stratégie s'accompagne de l'introduction d'encodages des indices de variables, permettant au modèle de distinguer les différentes dimensions lors du calcul de l'attention.

**TOTO** (Cohen et al., 2025), récemment proposé, est un décodeur (Figure 1(b)) basé sur un Transformer qui adopte une approche alternative pour le traitement des séries temporelles multivariées. Chaque série est d'abord découpée en plusieurs segments, puis un mécanisme d'attention à deux niveaux est appliqué : le premier capture les dépendances temporelles au sein de chaque série univariée, tandis que le second modélise les interactions entre séries via une attention dimensionnelle (Zhang et Yan, 2023). Cette architecture permet à TOTO de représenter efficacement à la fois les relations temporelles et inter-variables.

### 3.1.2 Modèles basés sur les réseaux récurrents

Les réseaux de neurones récurrents, en particulier les LSTM (Hochreiter et Schmidhuber, 1997), ont été largement utilisés pour la prévision de séries temporelles (Salinas et al., 2020). Le premier, et à ce jour le seul, modèle de fondation reposant sur une architecture récurrente est **TiRex** (Auer et al., 2025). Il s'agit d'un décodeur (Figure 1(b)) basé sur le sLSTM (Beck et al., 2024), une extension du LSTM classique qui introduit une activation exponentielle à la place de la fonction sigmoïde, laquelle contraint la sortie à l'intervalle  $[0, 1]$ . Cette modification confère au réseau une expressivité accrue. TiRex segmente les séries temporelles en segments. Contrairement aux décodeurs autoregressifs, qui génèrent les prévisions segment par segment (par exemple lors de l'inférence) en réinjectant chaque sortie prédite à l'entrée — ce qui accentue l'accumulation d'erreurs —, TiRex considère les segments futurs comme des valeurs manquantes, évitant ainsi la propagation d'erreurs et améliorant la stabilité des prévisions à long terme.

## 3.2 Pré-entraînement

Le pré-entraînement constitue une étape initiale et essentielle dans la construction des modèles de fondation pour les séries temporelles. Les connaissances acquises au cours de cette phase permettent aux modèles de mieux généraliser à travers différents contextes. Cependant, la diversité des styles architecturaux et des types de prévision visés (par exemple, encodeurs avec masquage, décodeurs autoregressifs, ou encore prévision probabiliste versus ponctuelle) conduit à une grande variété de mécanismes de pré-entraînement et de stratégies d'optimisation lors de la conception et du développement de ces modèles.

Le pré-entraînement est effectué de manière auto-supervisée, sans nécessiter d'annotation des données. Chronos (Ansari et al., 2024) est pré-entraîné en minimisant la fonction d'entropie croisée sur les jetons générés de manière autoregressive pour un horizon de prédiction fixe. Le modèle apprend à prédire une distribution sur l'ensemble des jetons définis, ce qui lui permet de générer des prévisions probabilistes (par exemple pour les quantiles 0.1, 0.2, ..., 0.9).

TimesFM (Das et al., 2024) et TiRex (Auer et al., 2025) partagent la même idée de pré-entraînement. Pour une séquence de segments d'entrée, le modèle est optimisé pour prédire le segment suivant à partir des précédents en minimisant la fonction de perte de quantile définie

Modèles de fondation pour la prévision des séries temporelles

par :

$$\mathcal{L}(y_{T+1:T+H}, \hat{y}_{T+1:T+H}^q; Q) = \frac{1}{|Q| H} \sum_{t=T+1}^{T+m_{\text{out}}} \sum_{q \in Q} (q - \mathbf{1}_{\{y_t - \hat{y}_t^q < 0\}}) (y_t - \hat{y}_t^q), \quad (1)$$

où  $Q$  désigne l'ensemble des niveaux de quantile,  $\hat{y}_t^q$  est la prédiction du modèle pour le niveau de quantile  $q$  à l'instant  $t$  et  $y_t$  est la valeur réelle.

TiRex utilise, lors de l'inférence, la prédiction multi-segment en traitant les segments futurs comme des données manquantes (en limitant l'accès à ces parties lors du calcul de l'attention) afin d'éviter l'autoregressivité. Pour simuler ce comportement lors du pré-entraînement, le modèle applique un masquage de segments contigus en masquant aléatoirement un ensemble de segments consécutifs dans la série d'entrée, reproduisant ainsi un scénario d'inférence.

Le modèle Moirai (Woo et al., 2024) est pré-entraîné en maximisant la log-vraisemblance d'une distribution de mélange paramétrique combinant plusieurs lois (Student-t, binomiale négative, log-normale et normale) afin de modéliser différents types de données temporelles. L'entraînement est réalisé sur un large corpus appelé *LOTSA* selon une distribution hiérarchique de données et de tâches. Cette stratégie permet au modèle d'apprendre à partir de fenêtres de contexte et d'horizon de longueurs variables, ainsi que de séries multi-domaines et multivariées, ce qui renforce sa capacité de généralisation.

### 3.3 Apprentissage par transfert : Ajustement sur des tâches spécifiques

L'ajustement, ou *fine-tuning*, des modèles de fondation est une technique d'apprentissage par transfert qui consiste à exploiter les connaissances acquises lors du pré-entraînement sur de vastes ensembles de données pour améliorer les performances sur une tâche cible. Cette approche est particulièrement cruciale dans le domaine de la prévision temporelle, où les jeux de données disponibles sont souvent de petite taille (par exemple, une seule série temporelle), limitant ainsi l'efficacité des modèles d'apprentissage automatique classiques qui nécessitent un grand nombre d'exemples pour bien fonctionner. En réutilisant les représentations apprises sur d'autres domaines, l'ajustement permet de contourner cette contrainte. Nie et al. (2023) a notamment démontré les effets positifs de l'ajustement de modèles pré-entraînés basés sur des architectures de type Transformer. Deux approches principales peuvent être envisagées : (i) ajuster l'ensemble des paramètres du modèle en poursuivant l'entraînement sur la tâche cible ; ou (ii) n'ajuster que certaines parties spécifiques du modèle — comme les couches de projection linéaires d'entrée et de sortie, ou certaines couches du Transformer — tout en conservant les autres paramètres figés.

## 4 Expérimentations

### 4.1 Données utilisées et modèles expérimentés

Nous menons notre étude d'ajustement sur l'ensemble de jeux de données constituant la partie train/test du benchmark GIFT-Eval (Aksu et al., 2024), un vaste cadre d'évaluation dédié aux modèles de prévision. Cette section du benchmark comprend 15 jeux de données univariées et 8 multivariées, couvrant 7 domaines et 10 fréquences différentes, pour un total de

144 000 séries temporelles et 177 millions d’observations. Au total, 92 configurations uniques, combinant jeu de données, fréquence et horizon de prévision (court, moyen et long terme), sont considérées, offrant ainsi une évaluation exhaustive et diversifiée des capacités d’ajustement des modèles de fondation de prévision. Une description complète du jeu de données est fournie dans Aksu et al. (2024) (Voir l’Annexe pour plus de détails sur les jeux de données utilisés).

Le choix des modèles repose sur deux critères : leurs performances (MWQL) sur le benchmark GiftEval et la disponibilité du code de reproduction. Parmi ceux dont le code d’entraînement est accessible, nous avons ainsi retenu le meilleur modèle de la section zero-shot et les deux meilleurs modèles de la section pre-trained du tableau de bord GiftEval<sup>1</sup> à la date de notre étude. Cette sélection couvre les principales familles d’architectures de modèles de fondation pour la prévision : Moirai-1.1-R-Large (310M paramètres, Encoder-only), Chronos-Bolt-Base (205M paramètres, Encoder-Decoder) et TimesFM-2.0 (500M paramètres, Decoder-only).

Dans notre étude, nous comparons les performances de ces modèles ajustés (Full Fine-Tuning, FFT) à celles de leurs versions zero-shot. Il est toutefois important de noter que Chronos-Bolt-Base et TimesFM-2.0 ont été pré-entraînés sur une partie limitée des ensembles de train/test du benchmark GIFT-Eval. Par conséquent, pour certains jeux de données de notre benchmark, l’évaluation de ces modèles en mode zero-shot n’est pas entièrement fiable car ils ont potentiellement été exposés à une partie des données de test durant le pré-entraînement. Cependant, dans notre étude, l’impact de cette contamination Pré-entraînement/Test demeure limité puisque nous comparons chaque modèle zero-shot uniquement à sa propre version ajustée, les deux partageant le même jeu de données de pré-entraînement. Cet effet devient en revanche plus significatif lorsqu’on compare différents modèles en zero-shot, comme le souligne Aksu et al. (2024).

## 4.2 Protocole expérimental

Nous avons choisi d’ajuster entièrement les modèles (ajuster l’ensemble de leurs paramètres) sur chaque tâche cible, car leur taille relativement modeste — au maximum 500 millions de paramètres — offre une plus grande flexibilité pour l’ajustement. Étant donné le grand nombre d’expériences à effectuer, nous n’effectuons pas la recherche des hyperparamètres optimaux pour chaque tâche ; nous utilisons plutôt les mêmes hyperparamètres pour un modèle donné sur l’ensemble des tâches. Le Tableau 1 présente les hyperparamètres employés pour l’ajustement de chaque modèle, pour lesquels nous retenons les valeurs par défaut. L’étude de la sélection d’hyperparamètres optimale est laissée à de futurs travaux.

**Métriques d’évaluation.** Nous évaluons la performance des modèles de prévision à l’aide de deux métriques complémentaires : l’erreur moyenne absolue en pourcentage (*Mean Absolute Percentage Error*, MAPE) pour la prévision ponctuelle, et le score de probabilité classé continu (*Continuous Ranked Probability Score*, CRPS) pour la prévision probabiliste.

La MAPE mesure la différence moyenne absolue en pourcentage entre les valeurs prédites  $\hat{y}_t$  (nous utilisons la prédiction de la médiane) et les valeurs réelles  $y_t$ , et est défini par :

$$\text{MAPE} = \frac{100}{H} \sum_{t=T+1}^{T+H} \left| \frac{y_t - \hat{y}_t}{y_t} \right|, \quad (2)$$

---

1. <https://huggingface.co/spaces/Salesforce/GIFT-Eval>

## Modèles de fondation pour la prévision des séries temporelles

Paramètre	Moirai-1.1-R-Large	Chronos-Bolt-Base	TimesFM-2.0
Taux d'apprentissage	$1 \times 10^{-7}$	$1 \times 10^{-5}$	$1 \times 10^{-6}$
Batch size	64	256	128
Nombre max. d'itérations de gradient	4000	4000	4000
Fonction optimisée	Vraisemblance de loi de mélange	Perte Quantile	Perte Quantile

TAB. 1 – *Hyperparamètres et fonction de perte utilisée pour l'ajustement des modèles de fondation.*

où  $H$  représente la taille de l'horizon.

Le CRPS est une métrique utilisée en prévision probabiliste pour évaluer la précision des fonctions de répartition  $F$  prédites par rapport aux valeurs observées. Pour une valeur réelle  $y$ , le CRPS est défini comme :

$$\text{CRPS}(F, y) = \int_0^1 2 \Lambda_\alpha(F^{-1}(\alpha), y) d\alpha, \quad (3)$$

où la perte quantile  $\Lambda_\alpha(q, y)$  est donnée par :  $\Lambda_\alpha(q, y) = (\alpha - \mathbf{1}_{\{y < q\}})(y - q)$ , avec  $\mathbf{1}_{\{y < q\}}$  l'indicateur valant 1 si  $y < q$ , et 0 sinon.

En pratique, le calcul intégral du CRPS peut être coûteux en termes de complexité computationnelle, et nous l'approximons par une somme discrète sur un ensemble fini de niveaux de quantiles. Cette approximation, souvent appelée perte quantile pondérée moyenne (*Mean Weighted Quantile Loss*, Aksu et al. (2024)), est définie par :

$$\text{MWQL} = \frac{2}{K} \sum_{k=1}^K \frac{\sum_{t=T+1}^{T+H} \Lambda_{\alpha_k}(\hat{q}_t(\alpha_k), y_t)}{\sum_{t=T+1}^{T+H} |y_t|},$$

où  $K$  est le nombre de niveaux de quantiles,  $Q = \{\alpha_1, \alpha_2, \dots, \alpha_K\}$  l'ensemble des quantiles retenus avec  $\alpha_k = 0.1k$  pour  $k \in \{1, 2, \dots, 9\}$  lorsque  $K = 9$ ,  $\hat{q}_t(\alpha)$  le quantile prédit au niveau  $\alpha$  à l'instant  $t$ ,  $y_t$  la valeur observée réelle, et  $\Lambda_\alpha(\hat{q}_t(\alpha), y_t)$  la perte quantile, laquelle caractérise la discordance entre le quantile prédit et l'observation via une pénalisation asymétrique dépendant de  $\alpha$ .

Il convient de noter que la fonction de perte de quantile et la vraisemblance du modèle de mélange (utilisée dans l'apprentissage des modèles utilisés, voir Tableau 1) sont directement liées au MWQL. L'optimisation de ces fonctions se traduit donc par une réduction du MWQL, améliorant la qualité des prévisions probabilistes.

Comme la magnitude des métriques d'évaluation peut varier d'un jeu de données à l'autre, nous normalisons les métriques de chaque modèle en les divisant par celles d'un modèle de référence (ici, Seasonal Naive) :  $\frac{\text{Metric}_{\text{model}}}{\text{Metric}_{\text{ref}}}$ . Les scores relatifs obtenus sont ensuite agrégés à l'aide de la moyenne arithmétique. Nous notons  $\text{MWQL}_n$  et  $\text{MAPE}_n$  ces métriques relatives.

### 4.3 Résultats et Analyse

Nous présentons les résultats selon deux axes d'analyse. Premièrement, nous agrégeons les performances en fonction de la taille des jeux de données — petits, moyens et grands (définis à partir des quantiles 0.33 et 0.66 de la distribution du nombre d'observations par jeu de données)

<b>Modèle</b>	<b>Config</b>	<b>Petit</b>		<b>Moyen</b>		<b>Grand</b>	
		$\text{MWQL}_n$	$\text{MAPE}_n$	$\text{MWQL}_n$	$\text{MAPE}_n$	$\text{MWQL}_n$	$\text{MAPE}_n$
Moirai-1.1-R-L	Zero-shot	0.634	0.745	0.541	0.862	0.353	<b>0.939</b>
Moirai-1.1-R-L	FFT	<b>0.544±0.007</b>	<b>0.627±0.009</b>	<b>0.414±0.000</b>	<b>0.763±0.002</b>	<b>0.310±0.000</b>	1.056±0.013
Chronos-Bolt-Base	Zero-shot	0.594	0.768	0.513	1.111	0.311	<b>0.895</b>
Chronos-Bolt-Base	FFT	<b>0.559±0.020</b>	<b>0.683±0.018</b>	<b>0.431±0.001</b>	<b>0.687±0.012</b>	<b>0.309±0.005</b>	0.991±0.034
TimesFM-2.0	Zero-shot	0.593	0.736	0.476	<b>0.848</b>	0.344	<b>1.178</b>
TimesFM-2.0	FFT	<b>0.591±0.002</b>	<b>0.735±0.005</b>	<b>0.468±0.003</b>	0.893±0.011	<b>0.328±0.002</b>	1.233±0.033

TAB. 2 – Moyennes de  $\text{MWQL}_n$  et  $\text{MAPE}_n$  selon la taille des jeux de données (petit, moyen, grand), avec distinction entre les modes Zero-shot et en full fine-tuning (FFT).

— afin d'évaluer l'impact de la taille de données sur la qualité de l'ajustement. Deuxièmement, pour obtenir une vision plus détaillée des performances, nous agrégeons les résultats selon le type d'horizon de prévision (court, moyen et long terme, tel que défini dans Aksu et al. (2024)) au sein de chaque domaine d'application (énergie, ventes, finance, etc.).

**Taille des jeux de données (Voir Tableau 2) :** Concernant le  $\text{MWQL}_n$ , qui est le critère optimisé pendant l'ajustement, nous observons une amélioration systématique après ajustement pour l'ensemble des modèles et des tailles de jeux de données. Pour Moirai et Chronos, cette amélioration est particulièrement marquée sur les jeux de données de petite et moyenne taille. Cela s'explique par le fait qu'avec un nombre d'itérations de gradient fixe pour tous les ensembles, ces modèles ont pu parcourir plusieurs fois les jeux de données de taille réduite. Ainsi, ils ont davantage consolidé l'apprentissage des motifs récurrents présents dans ces ensembles. En revanche, pour les grands jeux de données, les modèles n'ont pas eu l'occasion de voir la totalité des exemples, ce qui limite l'effet de l'ajustement.

À l'inverse, TimesFM présente une amélioration du  $\text{MWQL}_n$  plus significative sur les grands jeux de données. Cela peut s'expliquer par sa capacité à mieux exploiter la diversité des exemples, plutôt que la fréquence d'exposition aux mêmes données.

Enfin, en ce qui concerne la  $\text{MAPE}_n$ , celle-ci s'améliore globalement après ajustement, à l'exception des grands jeux de données où une dégradation est observée. Cette baisse de performance peut s'expliquer par une plus grande variabilité des valeurs cibles et par le fait que la  $\text{MAPE}_n$  n'a pas été optimisée lors de l'ajustement.

**Domaines et horizons (voir Tableaux 3 et 4) :** Nous constatons que les performances obtenues après ajustement varient selon le modèle et le domaine étudié. Concernant le  $\text{MWQL}_n$ , le modèle Moirai ajusté parvient à améliorer les résultats dans la grande majorité des cas. L'amélioration est particulièrement marquée pour les horizons moyens et longs dans les domaines du Transport, du Web/CloudOps et de l'Énergie, où la version en zero-shot montre des performances limitées. Cela suggère que l'ajustement constitue une étape essentielle pour renforcer la qualité des prévisions à moyen et long terme.

Le modèle Chronos-Bolt-Base ajusté surpassé généralement sa version zero-shot en terme de  $\text{MWQL}_n$  dans la plupart des domaines, à l'exception du domaine Énergie, où une légère dégradation est observée. Cette baisse peut s'expliquer par un surapprentissage dû à la nature spécifique de ce domaine, souvent marqué par un changement de distribution entre les ensembles d'entraînement et de test (Wang et al., 2024). Dans ce cas, un ajustement plus fin serait nécessaire — notamment en optimisant les hyperparamètres (tels que le taux d'apprentis-

## Modèles de fondation pour la prévision des séries temporelles

Modèle	Config	Transport			Nature			Web/CloudOps		
		Short	Medium	Long	Short	Medium	Long	Short	Medium	Long
MWQL <sub>n</sub>										
Moirai-1.1-R-L	Zero-shot	0.347	0.147	0.132	0.431	0.229	0.186	0.699	0.653	0.686
Moirai-1.1-R-L	FFT	<b>0.340 ± 0.000</b>	<b>0.130 ± 0.000</b>	<b>0.114 ± 0.000</b>	<b>0.398 ± 0.002</b>	<b>0.220 ± 0.001</b>	<b>0.181 ± 0.001</b>	<b>0.534 ± 0.006</b>	<b>0.416 ± 0.007</b>	<b>0.449 ± 0.002</b>
Chronos-Bolt-Base	Zero-Shot	0.339	0.184	0.168	<b>0.371</b>	0.177	0.145	0.772	0.698	0.696
Chronos-Bolt-Base	FFT	<b>0.329 ± 0.000</b>	<b>0.152 ± 0.001</b>	<b>0.138 ± 0.003</b>	0.403 ± 0.009	<b>0.171 ± 0.001</b>	<b>0.138 ± 0.001</b>	<b>0.580 ± 0.014</b>	<b>0.452 ± 0.010</b>	<b>0.402 ± 0.010</b>
TimesFM-2.0	Zero-Shot	<b>0.326</b>	0.177	0.154	0.467	<b>0.251</b>	0.224	0.579	<b>0.627</b>	<b>0.667</b>
TimesFM-2.0	FFT	<b>0.326 ± 0.000</b>	<b>0.170 ± 0.001</b>	<b>0.142 ± 0.001</b>	<b>0.433 ± 0.002</b>	<b>0.251 ± 0.002</b>	<b>0.223 ± 0.001</b>	<b>0.559 ± 0.004</b>	0.639 ± 0.017	0.698 ± 0.009
MAPE <sub>n</sub>										
Moirai-1.1-R-L	Zero-shot	<b>0.576</b>	0.559	0.458	0.733	<b>0.752</b>	<b>0.970</b>	0.679	1.103	1.097
Moirai-1.1-R-L	FFT	0.583 ± 0.007	<b>0.524 ± 0.007</b>	<b>0.449 ± 0.011</b>	<b>0.693 ± 0.003</b>	0.833 ± 0.003	0.975 ± 0.008	<b>0.572 ± 0.012</b>	<b>0.717 ± 0.020</b>	<b>0.595 ± 0.007</b>
Chronos-Bolt-Base	Zero-Shot	0.615	0.652	0.626	<b>0.614</b>	<b>0.632</b>	<b>0.785</b>	0.958	1.787	1.882
Chronos-Bolt-Base	FFT	<b>0.530 ± 0.003</b>	<b>0.560 ± 0.016</b>	<b>0.403 ± 0.045</b>	0.674 ± 0.030	0.677 ± 0.022	0.824 ± 0.007	<b>0.662 ± 0.037</b>	<b>0.503 ± 0.019</b>	<b>0.553 ± 0.066</b>
TimesFM-2.0	Zero-Shot	0.611	<b>0.506</b>	0.531	<b>0.767</b>	<b>0.488</b>	<b>0.709</b>	<b>0.673</b>	1.399	1.474
TimesFM-2.0	FFT	<b>0.601 ± 0.005</b>	0.509 ± 0.001	<b>0.471 ± 0.007</b>	0.850 ± 0.026	0.532 ± 0.009	0.748 ± 0.010	0.716 ± 0.012	<b>1.352 ± 0.075</b>	<b>1.354 ± 0.081</b>

TAB. 3 – Moyennes de MWQL<sub>n</sub> et MAPE<sub>n</sub> selon les domaines (Transport, Nature et Web/CloudOps) et horizon (court/moyen/long) pour les trois modèles, en zéro-shot et en full fine-tuning (FFT).

Modèle	Config	Econ/Fin		Énergie			Santé		Ventes	
		Short	Short	Medium	Long	Short	Short	Short	Short	Short
MWQL <sub>n</sub>										
Moirai-1.1-R-L	Zero-shot	0.943	0.586	0.333	0.300	0.544	0.525			
Moirai-1.1-R-L	FFT	<b>0.715 ± 0.002</b>	<b>0.564 ± 0.007</b>	<b>0.280 ± 0.001</b>	<b>0.245 ± 0.001</b>	<b>0.462 ± 0.002</b>	<b>0.387 ± 0.001</b>			
Chronos-Bolt-Base	Zero-Shot	0.601	<b>0.525</b>	<b>0.286</b>	<b>0.259</b>	0.483	0.384			
Chronos-Bolt-Base	FFT	<b>0.598 ± 0.002</b>	0.588 ± 0.018	0.309 ± 0.006	0.289 ± 0.001	<b>0.459 ± 0.012</b>	<b>0.382 ± 0.001</b>			
TimesFM-2.0	Zero-Shot	0.660	0.596	0.301	0.277	0.407	0.377			
TimesFM-2.0	FFT	<b>0.620 ± 0.004</b>	<b>0.573 ± 0.002</b>	<b>0.300 ± 0.012</b>	<b>0.274 ± 0.002</b>	<b>0.390 ± 0.001</b>	<b>0.374 ± 0.001</b>			
MAPE <sub>n</sub>										
Moirai-1.1-R-L	Zero-shot	1.128	<b>0.938</b>	0.991	<b>1.249</b>	0.716	0.766			
Moirai-1.1-R-L	FFT	<b>0.855 ± 0.002</b>	1.003 ± 0.016	<b>0.957 ± 0.009</b>	1.990 ± 0.054	<b>0.585 ± 0.002</b>	<b>0.737 ± 0.001</b>			
Chronos-Bolt-Base	Zero-Shot	<b>0.663</b>	<b>1.065</b>	<b>0.837</b>	<b>0.932</b>	0.650	<b>0.681</b>			
Chronos-Bolt-Base	FFT	0.674 ± 0.001	1.141 ± 0.028	1.044 ± 0.042	1.517 ± 0.045	<b>0.577 ± 0.008</b>	0.736 ± 0.007			
TimesFM-2.0	Zero-Shot	0.725	<b>1.131</b>	<b>1.225</b>	<b>1.575</b>	0.577	<b>0.635</b>			
TimesFM-2.0	FFT	<b>0.708 ± 0.005</b>	1.136 ± 0.007	1.315 ± 0.089	1.920 ± 0.086	<b>0.556 ± 0.006</b>	0.706 ± 0.002			

TAB. 4 – Moyennes de MWQL<sub>n</sub> et MAPE<sub>n</sub>) selon les domaines (Économie/Finance, Énergie, Santé et Ventes) et horizon (court/moyen/long) pour les trois modèles, en zéro-shot et en full fine-tuning (FFT).

sage et le nombre maximal d’itérations de gradient) et en appliquant une régularisation adaptée pour limiter le surapprentissage et améliorer la généralisation. Quant à TimesFM-2.0 ajusté, l’amélioration du MWQL<sub>n</sub> est quasi systématique, à l’exception du domaine Web/CloudOps, où la version zero-shot reste supérieure.

En revanche, pour la MAPE<sub>n</sub>, les performances des modèles ajustés se dégradent dans plusieurs domaines et horizons, contrairement à l’amélioration observée pour le MWQL<sub>n</sub>, notamment pour Chronos-Bolt-Base et TimesFM. Cette dégradation peut s’expliquer par le fait que la fonction de perte de quantile utilisée lors de l’ajustement privilégie l’optimisation du MWQL<sub>n</sub>, parfois au détriment de la MAPE<sub>n</sub>, qui n’est représentée que par un seul quantile (la médiane) dans cette fonction.

## 5 Conclusion et perspective

Dans cet article, nous avons présenté une revue des modèles de fondation pour la prévision de séries temporelles, en les analysant sous plusieurs angles : architecture, pré-entraînement

et adaptation par ajustement. Nous avons ensuite étudié l'effet de l'ajustement de ces modèles sur des jeux de données cibles, montrant que, avec un choix approprié des hyperparamètres, cette étape permet d'améliorer significativement les performances zero-shot, notamment pour les prévisions à long terme, où les modèles zero-shot tendent à être moins performants.

Le domaine des modèles de fondation pour la prévision de séries temporelles est très récent et présente encore de nombreux défis. D'une part, contrairement au NLP, les séries temporelles restent peu accessibles et souvent conservées par les grandes entreprises industrielles, ce qui limite la disponibilité de jeux de données vastes et diversifiés pour la recherche. D'autre part, les modèles de fondation appliqués aux séries temporelles manquent encore d'études théoriques et empiriques permettant de mieux comprendre leur comportement en matière de généralisation et de compression de l'information, d'autant plus que les séries temporelles présentent une forte hétérogénéité, rendant l'apprentissage d'un préviseur universel particulièrement difficile.

## Références

- Aksu, T., G. Woo, J. Liu, X. Liu, C. Liu, S. Savarese, C. Xiong, et D. Sahoo (2024). GIFT-eval : A benchmark for general time series forecasting model evaluation. In *NeurIPS Workshop on Time Series in the Age of Large Models*.
- Ansari, A. F., L. Stella, A. C. Turkmen, X. Zhang, P. Mercado, H. Shen, O. Shchur, S. S. Rangapuram, S. P. Arango, S. Kapoor, J. Zschiegner, D. C. Maddix, H. Wang, M. W. Mahoney, K. Torkkola, A. G. Wilson, M. Bohlke-Schneider, et B. Wang (2024). Chronos : Learning the language of time series. *Transactions on Machine Learning Research*. Expert Certification.
- Auer, A., P. Podest, D. Klotz, S. Böck, G. Klambauer, et S. Hochreiter (2025). TiRex : Zero-Shot Forecasting Across Long and Short Horizons with Enhanced In-Context Learning. *ArXiv 2505.23719*.
- Beck, M., K. Pöppel, M. Spanring, A. Auer, O. Prudnikova, M. Kopp, G. Klambauer, J. Brandstetter, et S. Hochreiter (2024). xlstm : Extended long short-term memory. In *Thirty-eighth Conference on Neural Information Processing Systems*.
- Box, G. E., G. M. Jenkins, G. C. Reinsel, et G. M. Ljung (2015). *Time series analysis : forecasting and control*. John Wiley & Sons.
- Cohen, B., E. Khwaja, Y. Doubli, S. Lemaachi, C. Lettieri, C. Masson, H. Miccinilli, E. Ramé, Q. Ren, A. Rostamizadeh, J. O. du Terrail, A.-M. Toon, K. Wang, S. Xie, Z. Xu, V. Zhukova, D. Asker, A. Talwalkar, et O. Abou-Amal (2025). This time is different : An observability perspective on time series foundation models. In *The Thirty-ninth Annual Conference on Neural Information Processing Systems*.
- Das, A., W. Kong, R. Sen, et Y. Zhou (2024). A decoder-only foundation model for time-series forecasting. In *Proceedings of the 41st International Conference on Machine Learning, ICML'24*. JMLR.org.
- Dudek, G. (2022). A comprehensive study of random forest for short-term load forecasting. *Energies* 15(20), doi: 10.3390/en15207547.
- Gardner, E. (2006). Exponential smoothing : The state of the art—part ii. *International Journal of Forecasting* 22, 637–666, doi: 10.1016/j.ijforecast.2006.03.005.

## Modèles de fondation pour la prévision des séries temporelles

- Godahewa, R. W., C. Bergmeir, G. I. Webb, R. Hyndman, et P. Montero-Manso (2021). Mnash time series forecasting archive. In *Thirty-fifth Conference on Neural Information Processing Systems Datasets and Benchmarks Track (Round 2)*.
- Hochreiter, S. et J. Schmidhuber (1997). Long short-term memory. *Neural Comput.* 9(8), 1735–1780, doi: 10.1162/neco.1997.9.8.1735.
- Lai, G., W.-C. Chang, Y. Yang, et H. Liu (2017). Modeling long- and short-term temporal patterns with deep neural networks. *The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval*.
- Mancuso, P., V. Piccialli, et A. M. Sudoso (2020). A machine learning approach for forecasting hierarchical time series. *Expert Syst. Appl.* 182, 115102.
- Nie, Y., N. H. Nguyen, P. Sinthong, et J. Kalagnanam (2023). A time series is worth 64 words : Long-term forecasting with transformers. In *International Conference on Learning Representations*.
- Palaskar, S., V. Ekambaram, A. Jati, N. Gantayat, A. Saha, S. Nagar, N. H. Nguyen, P. Dayama, R. Sindhgatta, P. Mohapatra, H. Kumar, J. Kalagnanam, N. Hemachandra, et N. Rangaraj (2024). Automixer for improved multivariate time-series forecasting on business and it observability data. In *Proceedings of the Thirty-Eighth AAAI Conference on Artificial Intelligence and Thirty-Sixth Conference on Innovative Applications of Artificial Intelligence and Fourteenth Symposium on Educational Advances in Artificial Intelligence, AAAI'24/IAAI'24/EAAI'24*. AAAI Press, doi: 10.1609/aaai.v38i21.30336.
- Salinas, D., V. Flunkert, J. Gasthaus, et T. Januschowski (2020). Deepar : Probabilistic forecasting with autoregressive recurrent networks. *International Journal of Forecasting* 36(3), 1181–1191, doi: <https://doi.org/10.1016/j.ijforecast.2019.07.001>.
- Shen, S., V. van Beek, et A. Iosup (2015). Statistical characterization of business-critical workloads hosted in cloud datacenters. In *Proceedings of the 15th IEEE/ACM International Symposium on Cluster, Cloud, and Grid Computing, CCGRID '15*, pp. 465–474. IEEE Press, doi: 10.1109/CCGrid.2015.60.
- Trindade, A. (2015). ElectricityLoadDiagrams20112014. UCI Machine Learning Repository. DOI : <https://doi.org/10.24432/C58C86>.
- Vaswani, A., N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. u. Kaiser, et I. Polosukhin (2017). Attention is all you need. In I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, et R. Garnett (Eds.), *Advances in Neural Information Processing Systems*, Volume 30. Curran Associates, Inc.
- Wang, J., J. Jiang, W. Jiang, C. Han, et W. X. Zhao (2023). Towards efficient and comprehensive urban spatial-temporal prediction : A unified library and performance benchmark. *ArXiv abs/2304.14343*.
- Wang, S., H. Wu, X. Shi, T. Hu, H. Luo, L. Ma, J. Y. Zhang, et J. ZHOU (2024). Timemixer : Decomposable multiscale mixing for time series forecasting. In *International Conference on Learning Representations (ICLR)*.
- Woo, G., C. Liu, A. Kumar, C. Xiong, S. Savarese, et D. Sahoo (2024). Unified training of universal time series forecasting transformers. In *Forty-first International Conference on Machine Learning*.

- Wu, H., J. Xu, J. Wang, et M. Long (2021). Autoformer : Decomposition transformers with auto-correlation for long-term series forecasting. In *Neural Information Processing Systems*.
- Zeng, A., M. Chen, L. Zhang, et Q. Xu (2023). Are transformers effective for time series forecasting ? In *Proceedings of the AAAI Conference on Artificial Intelligence*.
- Zhang, Y. et J. Yan (2023). Crossformer : Transformer utilizing cross-dimension dependency for multivariate time series forecasting. In *The Eleventh International Conference on Learning Representations*.
- Zhou, H., S. Zhang, J. Peng, S. Zhang, J. Li, H. Xiong, et W. Zhang (2020). Informer : Beyond efficient transformer for long sequence time-series forecasting. *ArXiv abs/2012.07436*.

## A Informations complémentaires sur les jeux de données utilisés

### A.1 Caractéristiques des séries temporelles selon les différents domaines

Dans cette section, nous présentons une analyse détaillée des caractéristiques statistiques des séries temporelles issues des jeux de données train/test du benchmark GIFTEval Aksu et al. (2024). Cette analyse vise à mieux comprendre les particularités structurelles des données selon les différents domaines étudiés (finance, santé, énergie, transport, etc.). Pour cela, nous reprenons trois mesures fondamentales permettant d'étudier les caractéristiques et la prévisibilité d'une série temporelle à partir de son historique : la **tendance**, la **saisonnalité** et l'**entropie**.

**Tendance** La tendance mesure l'évolution globale d'une série temporelle au fil du temps (hausse, baisse ou stabilité). Elle est obtenue via une décomposition de la série en composantes de tendance, de saisonnalité et de résidu, puis en comparant la variance du composant résiduel à la variance combinée des composants de tendance et de résidu. La force de la tendance est définie comme suit :

$$\text{trend} = 1 - \frac{\text{Var}(e_t)}{\text{Var}(f_t + e_t)},$$

où  $f_t$  est la composante de tendance et  $e_t$  le résidu. Des valeurs proches de 1 indiquent une tendance marquée, comme c'est souvent le cas pour les séries économiques ou financières. À l'inverse, certaines séries provenant de domaines comme le transport présentent une tendance plus faible.

**Saisonnalité** La force de la saisonnalité traduit l'existence de motifs répétitifs à intervalles réguliers—par exemple des cycles journaliers (Ventes, énergie) ou annuels (finance). Elle est calculée pour chaque composante saisonnière  $s_{i,t}$  selon :

$$\text{seasonal\_strength}_i = 1 - \frac{\text{Var}(e_t)}{\text{Var}(s_{i,t} + e_t)}.$$

Une valeur élevée indique une présence forte de motifs récurrents, rendant la série plus structurée.

## Modèles de fondation pour la prévision des séries temporelles

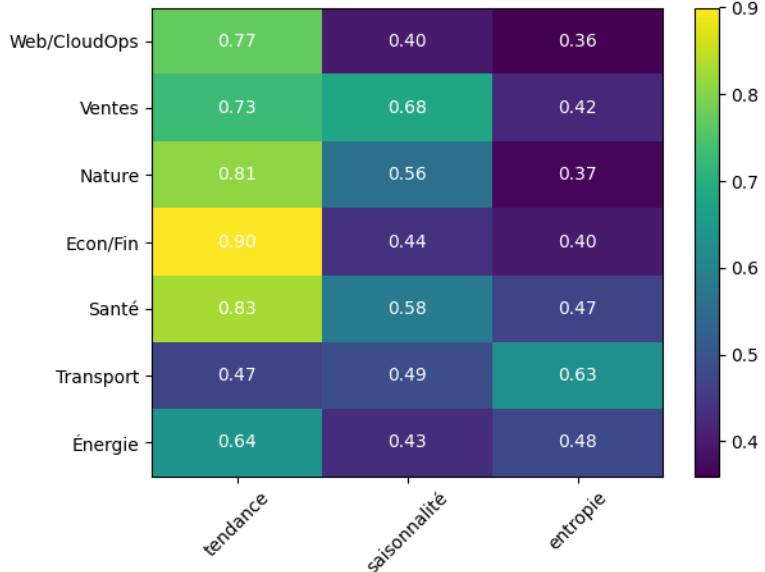


FIG. 2 – *Cartes thermiques représentant les valeurs moyennes de trois caractéristiques de séries temporelles selon les différents domaines du jeu de données.*

**Entropie / Prévisibilité** L’entropie spectrale mesure la complexité ou le niveau de bruit d’une série temporelle :

$$\text{Entropy} = - \int_{-\pi}^{\pi} \hat{f}(\lambda) \log \hat{f}(\lambda) d\lambda,$$

où  $\hat{f}(\lambda)$  est l’estimation de la densité spectrale. Une faible entropie traduit une structure forte et une série facilement prédictible, tandis qu’une entropie élevée caractérise un comportement irrégulier ou bruité.

La Figure 2 illustre les valeurs moyennes de ces trois caractéristiques pour chacun des domaines considérés, mettant en évidence des disparités structurelles importantes. Ces observations confirment l’importance d’évaluer les modèles de prévision sur un ensemble diversifié de conditions temporelles, comme le propose GIFTEval sur la figure 2.

## A.2 Jeux de données utilisés et tailles associées

Le tableau 5 présentons l’ensemble des jeux de données employés dans notre étude, ainsi que leurs caractéristiques principales, notamment leur taille, leur domaine, leur fréquence et la longueur moyenne des séries temporelles. Ces informations permettent de mieux comprendre la diversité et la complexité des données sur lesquelles les modèles sont évalués.

Jeu de données	Source	Domaine[Taille]	Fréquence	# Séries	Longueur des séries				Court terme		Moyen terme		Long terme				
					Moy.	Min	Max	# Obs.	Variables cibles	Horizon (C)	Fenêtres de Test	Horizon (M)	Fenêtres de Test	Horizon (L)	Fenêtres de Test		
Jena Weather	Autoformer (Wu et al., 2021)	Naturel[Grand]	10T	1	52,704	52,704	52,704	52,704	21	48	20	480	11	720	8		
Jena Weather	Autoformer (Wu et al., 2021)	Sales[Moyen]	H	1	8,784	8,784	8,784	8,784	11	48	19	480	2	720	2		
BuTTOs - Application	Auto-Mixer (Paluskar et al., 2024)	WebCloudOps[Petit]	10S	1	8,834	8,834	8,834	8,834	21	60	15	600	2	900	1		
BuTTOs - Service	Auto-Mixer (Paluskar et al., 2024)	WebCloudOps[Moyen]	10S	21	8,835	8,835	18,535	18,535	2	60	15	600	2	900	1		
BuTTOs - Auto	Auto-Mixer (Paluskar et al., 2024)	WebCloudOps[Grand]	5T	1	31,658	15,951	51,068	51,068	7	48	20	480	7	720	5		
BuTTOs - LNC	Auto-Mixer (Paluskar et al., 2024)	WebCloudOps[Petit]	H	1	2,664	2,664	2,664	2,664	7	48	6	480	1	720	1		
Bribains - Fast Storage	Grid Workloads Archive (Shen et al., 2015)	WebCloudOps[Grand]	5T	1,250	8,640	8,640	8,640	10,800,000	2	48	18	480	2	720	2		
Bribains - Grid Workloads Archive	Grid Workloads Archive (Shen et al., 2015)	WebCloudOps[Grand]	H	1,250	71,711	71,711	71,711	10,800,000	2	48	2	48	18	720	2		
Bribains - md	Grid Workloads Archive (Shen et al., 2015)	WebCloudOps[Grand]	H	500	8,640	8,640	8,640	4,320,000	2	48	2	480	2	720	2		
Bribains - md	Grid Workloads Archive (Shen et al., 2015)	WebCloudOps[Grand]	H	500	720	720	720	360,000	2	48	2	480	15	720	10		
ETT1	Informer (Zhou et al., 2020)	Energy[Moyen]	1ST	1	69,560	69,560	69,560	69,560	7	48	20	480	4	720	3		
ETT1	Informer (Zhou et al., 2020)	Energy[Petit]	H	1	17,420	17,420	17,420	17,420	7	48	20	480	4	720	3		
ETT2	Informer (Zhou et al., 2020)	Energy[Petit]	D	1	725	725	725	725	7	30	3	30	3	30	3		
ETT2	Informer (Zhou et al., 2020)	Energy[Petit]	W/THU	1	103	103	103	103	7	8	2	8	2	20	10		
ETT2	Informer (Zhou et al., 2020)	Energy[Petit]	W/THU	1	69,480	69,480	69,480	69,480	7	48	20	480	15	720	10		
ETT2	Informer (Zhou et al., 2020)	Energy[Moyen]	H	1	17,420	17,420	17,420	17,420	7	48	20	480	4	720	3		
ETT2	Informer (Zhou et al., 2020)	Energy[Petit]	D	1	725	725	725	725	7	30	3	30	3	30	3		
Loop Seattle	LibCity (Wang et al., 2023)	Transport[Grand]	ST	323	105,120	105,120	105,120	33,953,760	1	48	20	480	20	720	15		
Loop Seattle	LibCity (Wang et al., 2023)	Transport[Grand]	H	323	8,760	8,760	8,760	28,29,480	1	48	19	480	2	720	2		
Loop Seattle	LibCity (Wang et al., 2023)	Transport[Grand]	D	323	365	365	365	117,895	1	30	2	30	1	30	2		
SZ Taxi	LibCity (Wang et al., 2023)	Transport[Grand]	1ST	156	2,960	2,960	2,960	2,976,556	1	48	7	480	1	720	1		
SZ Taxi	LibCity (Wang et al., 2023)	Transport[Moyen]	H	156	744	744	744	116,064	1	48	2	480	20	480	4	720	3
M_DENSE	LibCity (Wang et al., 2023)	Transport[Grand]	H	30	17,520	17,520	17,520	525,600	1	48	1	480	1	720	1		
M_DENSE	LibCity (Wang et al., 2023)	Transport[Grand]	D	30	36	36	36	10,120	1	30	2	30	1	30	2		
Solar	LSTNet (Lai et al., 2017)	Energy[Grand]	10T	137	52,560	52,560	52,560	7,200,720	1	48	20	480	11	720	8		
Solar	LSTNet (Lai et al., 2017)	Energy[Grand]	H	137	8,760	8,760	8,760	1,200,120	1	48	19	480	2	720	2		
Solar	LSTNet (Lai et al., 2017)	Energy[Petit]	D	137	365	365	365	500,000	1	48	2	480	1	720	1		
Hierarchical Sales	Mancuso et al. (2020)	Sales[Moyen]	D	118	1,825	1,825	1,825	213,530	1	30	7	30	1	30	7		
Hierarchical Sales	Mancuso et al. (2020)	Sales[Petit]	W-WED	118	260	260	260	36,680	1	8	4	8	1	8	4		
M4 Daily	Monash (Goldobewa et al., 2021)	EconFin[Grand]	M	40,000	734	734	734	23,142,11,411	1	18	1	18	1	18	1		
M4 Weekly	Monash (Goldobewa et al., 2021)	EconFin[Grand]	M	359	1,035	93	93	2,610	1	13	1	13	1	13	1		
M4 Daily	Monash (Goldobewa et al., 2021)	EconFin[Grand]	D	4,227	2,371	107	107	9,930	1	14	1	14	1	14	1		
M4 Weekly	Monash (Goldobewa et al., 2021)	EconFin[Grand]	H	414	9,724	1,008	3,072	3,072	1	48	2	480	20	480	2		
Hospital	Monash (Goldobewa et al., 2021)	Healthcare[Moyen]	M	767	84	84	84	54,428	12	1	12	7	1	12	7		
COVID Deaths	Monash (Goldobewa et al., 2021)	Healthcare[Petit]	D	266	212	212	212	56,392	1	30	1	30	1	30	1		
US Births	Monash (Goldobewa et al., 2021)	Healthcare[Petit]	H	1	7,305	7,305	7,305	7,305	1	30	20	480	1	720	20		
US Births	Monash (Goldobewa et al., 2021)	Healthcare[Petit]	W-JUE	1	1,034	1,043	1,043	1,043	1	8	14	8	1	14	2		
US Births	Monash (Goldobewa et al., 2021)	Healthcare[Petit]	H	1	240	240	240	240	1	12	2	12	1	12	2		
Sausage	Monash (Goldobewa et al., 2021)	Nature[Petit]	D	1	23,741	23,741	23,741	23,741	1	30	20	480	1	720	1		
Sausage	Monash (Goldobewa et al., 2021)	Nature[Petit]	W/THU	1	3,140	3,140	3,140	3,140	1	8	20	480	1	720	1		
Sausage	Monash (Goldobewa et al., 2021)	Nature[Petit]	M	1	780	780	780	780	1	12	7	12	1	12	7		
Temperature Rain	Monash (Goldobewa et al., 2021)	Nature[Grand]	D	32,072	725	725	725	780	1	30	3	30	2	720	2		
KDD Cup 2018	Monash (Goldobewa et al., 2021)	Nature[Grand]	H	270	10,898	9,504	10,890	10,890,2,92,364	1	48	20	480	2	720	2		
KDD Cup 2018	Monash (Goldobewa et al., 2021)	Nature[Grand]	D	270	456	456	456	22,2791	1	30	2	30	1	30	2		
Cars Part	Monash (Goldobewa et al., 2021)	Sales[Moyen]	M	2,674	51	51	51	136,374	1	12	1	12	1	12	1		
Electricity	UCI ML Archive (Trindade, 2015)	Energy[Grand]	1ST	370	140,256	140,256	140,256	51,894,720	1	48	20	480	20	720	20		
Electricity	UCI ML Archive (Trindade, 2015)	Energy[Grand]	H	370	35,044	35,044	35,044	35,044,12,000,900	1	48	20	480	8	720	8		
Electricity	UCI ML Archive (Trindade, 2015)	Energy[Grand]	D	370	1,461	1,461	1,461	140,570	1	30	5	30	5	30	5		
Electricity	UCI ML Archive (Trindade, 2015)	Energy[Moyen]	W-FRI	370	208	208	208	76,960	1	8	3	8	3	8	3		

TAB. 5 – Statistiques individuelles de chaque jeu de données du benchmark, incluant notamment la taille de chacun d'eux.

## Summary

Inspired by recent advances in large language models, foundation models have been developed for zero-shot time series forecasting, enabling prediction on datasets unseen during pretraining. These large-scale models, trained on vast collections of time series, learn generalizable representations for both point and probabilistic forecasting, reducing the need for task-specific architectures and manual tuning.

In this work, we review the main architectures, pretraining strategies, and optimization methods used in such models, and study the effect of fine-tuning after pretraining to enhance their performance on specific datasets. Our empirical results show that fine-tuning generally improves zero-shot forecasting capabilities, especially for long-term horizons.