

Modélisation dynamique des erreurs de prévision de la consommation électrique

Roman LE GOFF LATIMIER

Univ Rennes, ENS Rennes, IETR, CNRS, Bruz, France

{roman.legoff-latimier}@ens-rennes.fr

RESUME – Malgré la qualité des prévisions de consommation électrique, des erreurs de prévision sont inéluctables dans tout exercice d’anticipation. Ces erreurs ne sont pas des bruits temporellement décorrélés puisqu’elles sont causées par des phénomènes physiques mal anticipés. Modéliser l’évolution de ces erreurs de prévision pourrait donc permettre d’améliorer la manière dont elles seront compensées en temps réel. Après avoir mis en lumière la structure temporelle complexe des erreurs de prévision J-1, cette contribution propose plusieurs modélisations de séries temporelles dont la qualité statistique est tout d’abord discutée. Dans un second temps, ces différents modèles sont utilisés pour résoudre le problème de compensation des erreurs de prévision à l’aide d’un stockage. Cette application illustrative permet de mettre en évidence que la qualité statistique d’un modèle n’est pas systématiquement associée à une valeur ajoutée dans un contexte applicatif de contrôle optimal.

Mots-clés – Erreurs de prévision, séries temporelles, contrôle optimal stochastique, modélisation orientée vers la valeur

1. INTRODUCTION

L’équilibre entre la production et la consommation étant au cœur de la gestion d’un réseau électrique, la prévision de la demande de consommation est de longue date une question cruciale [1]. Elle rend possible une anticipation pertinente des moyens de production à mobiliser. De plus l’intégration des offres de production et de consommation dans les marchés de l’électricité permet de réagir lorsque la prévision se précise à l’approche de l’échéance [2]. La succession des marchés J-1 puis intrajournalier permet de rectifier d’éventuelles erreurs de prévision.

En effet l’existence d’erreurs est inhérente à tout exercice de prévision. L’amplitude de l’incertitude peut être amenée à se réduire au fil de l’amélioration des méthodes de prévision. Néanmoins une erreur irréductible ne peut que perdurer, étant intrinsèquement liée à l’exercice d’anticiper des événements futurs. Les conséquences de ces erreurs se font directement sentir sur la performance de la gestion du réseau qui en découle [3]. Elles nécessitent la mise en place de capacités de réserve [4] et le recours aux centrales les plus réactives [5]. Ces dernières sont souvent les moins efficaces, générant des coûts financiers et environnementaux supplémentaires [6].

De ce fait, la caractérisation de la qualité d’une prévision est une thématique importante et active de la littérature [7]. Afin de mieux couvrir les événements peu probables mais possibles, les prévisions déterministes ont progressivement été remplacées par des prévisions stochastiques [8]. Celles-ci peuvent prendre la forme de densités de probabilité, ou bien d’ensemble de scénarios. Pour chacune de ces formes, des métriques spécifiques ont été élaborées afin de traduire la qualité de la prévision [9].

Cependant cette caractérisation de l’erreur ne capture pas toute l’information. Après que la prévision ait été livrée – typiquement toutes les 6 heures ou bien tous les jours – le gestionnaire n’a pas d’autre ressource jusqu’à la prochaine mise à jour. Il serait donc crucial de connaître le comportement dynamique de l’erreur de prévision, c’est à dire la manière dont celle-ci peut évoluer au cours du temps. En effet les causes des erreurs

de prévision sont le plus souvent des phénomènes météorologiques ou sociaux qui certes n’ont pas été correctement prévus, mais présentent tout de même une cohérence temporelle [10]. Connaître cette structure temporelle permettrait donc d’améliorer la gestion à court terme en anticipant l’évolution de l’erreur de prévision via des offres sur des marchés intrajournalier, l’activation de flexibilité ou bien l’activation de centrales de réserve [11].

La présente contribution cherche donc à proposer une modélisation dynamique de l’erreur de prévision, c’est à dire un modèle capable de prédire son évolution. A ce stade, des modèles de série temporelles seront privilégiés afin d’illustrer les autocorrélations contenues dans la série d’erreur. Dans la section 2, cette approche basée sur la qualité statistique cherchera à trouver les modèles les plus adaptés. Elle sera complétée dans la section 3 par une démarche tournée vers l’application : des modèles dynamiques de l’erreur de prévision seront utilisés au sein d’un problème de contrôle optimal visant à la compenser. Toutes les données et les codes utilisés pour obtenir les résultats présentés ici sont disponibles sur un dépôt open source [12].

2. MODÈLE DYNAMIQUE DES ERREURS DE PRÉVISION DE CONSOMMATION

Les données utilisées pour étudier l’erreur de prévision de la consommation électrique proviennent du gestionnaire du réseau de transport français RTE. Les séries temporelles de consommation P et de prévision $\tilde{P}$ sont fournies au pas de temps 30 min. La prévision considérée est celle de la veille pour le lendemain. On utilisera les données de l’année 2022 pour identifier les modèles. L’année 2023 sera utilisée pour les valider, puisqu’il n’y a pas de différence statistiquement notable dans le comportement de l’erreur de prévision au cours de ces deux années.

L’erreur de prévision ΔP est définie comme

$$\Delta P = P - \tilde{P} \quad (1)$$

La série est ensuite normalisée avant de l’utiliser pour identifier les modèles suivants. La suite de cette étude ne présentera donc que des données normalisées, dont l’amplitude n’est pas significative.

2.1. Description du modèle

Dans le cadre de cette contribution, on choisit de retenir des modèles de type séries temporelles suivants : AutoRegressive AR [13], AutoRegressive Moving Average ARMA, Seasonal AutoRegressive Integrated Moving Average SARIMA [14, 15] et Markov Switching AutoRegressive MSAR [16]. Ces modèles sont décrits par une équation dont les coefficients sont identifiés sur des données. Ce choix est motivé par le faible coût calculatoire associé à l’identification des paramètres, ainsi qu’à la génération de scénarios. De plus la structure du modèle choisi est directement reliée aux caractéristiques qu’il sera en mesure de capturer : saisonnalités, corrélation de court ou moyen terme.

Cette considération d'explicabilité du modèle est à ce stade déterminante pour défricher la modélisation adaptée aux erreurs de prévision de consommation électrique. De ce fait, des modèles moins explicables basés sur des données ont été exclus à ce stade, malgré leurs performances prometteuses pour de futures modélisations [1].

De manière générale, une variable X suit un processus AR(p)MA(q) si elle est décrite par l'équation suivante :

$$X(t) - \phi_1 X(t - \Delta T) - \dots - \phi_p X(t - p\Delta T) = \varepsilon(t) + \theta_1 \varepsilon(t - \Delta T) + \dots + \theta_q \varepsilon(t - q\Delta T) \quad (2)$$

où ε désigne un bruit gaussien indépendant et identiquement distribué. L'absence de terme θ conduit à un processus autorégressif. Certaines séries temporelles présentant des changements de dynamiques – par exemple l'alternance de tempêtes et d'anticyclones pour une série de vitesse de vent – il est possible d'étendre les modèles ARMA en ajoutant une chaîne de Markov décrivant un état caché $\pi(t)$, conduisant alors à des modèles MSAR [16]. La valeur de cet état non directement accessible sélectionne un jeu de coefficients $\{\phi\}$ parmi plusieurs possibles :

$$X(t) = \phi_1^{\pi(t)} X(t - \Delta T) + \dots + \phi_p^{\pi(t)} X(t - p\Delta T) + \varepsilon(t) \quad (3)$$

Enfin une autre extension de cette classe de modèle consiste à prendre en compte un effet saisonnier s via les modèles SARIMA. Ceci serait possible en augmentant l'ordre p , mais peut être fait de manière plus parcimonieuse en ajoutant uniquement des coefficients périodiquement placés $\{\phi_s, \phi_{2s}, \dots, \phi_{Ps}\}$.

2.2. Sélection d'un modèle et validation

Cette section présente les résultats obtenus par les différents modèles sur la série temporelle des erreurs de prévision. Leurs performances seront examinées en fonction de leur log-vraisemblance¹ et de leur critère d'information bayésien (BIC). Le BIC pénalise le nombre de paramètres utilisés : à vraisemblance égale, les modèles les plus simples sont privilégiés. D'autres métriques pertinentes auraient également pu être présentées ici, comme par exemple le Continuous Ranked Probability Score CRPS [9]. Bien qu'elles aient des significations différentes, ces différentes métriques ont donné lors de cette étude des résultats essentiellement similaires, d'où le choix de présenter ici exclusivement des valeurs de BIC.

La capacité à capturer la structure temporelle est illustrée sur la figure 1. Elle illustre l'autocorrélation de la série réelle et de la série artificielle générée selon les différents modèles étudiés. Ces séries, comme les prévisions utilisées ci-après, sont dérivées de (2) et (3), pour plusieurs réalisations de ε . Un autre angle sous lequel la qualité des modèles sera évaluée est la capacité des séries temporelles artificielles à reproduire les caractéristiques indirectes de la série originale. Certaines caractéristiques peuvent être particulièrement difficiles à imiter, comme le nombre de fois où la série franchit un seuil, qui est étudié sur la figure 2.

La figure 1 représente en bleu l'autocorrélation de la série de données utilisée. Le pas de temps de données étant de 30 min, une journée correspond au lag 48. On remarque tout d'abord une autocorrélation importante entre des instants consécutifs. D'autre part un pic d'autocorrélation quotidien est notable. En effet la série d'erreur de prévision fut constituée à l'aide d'une prévision un jour à l'avance. Une autocorrélation significative non nulle peut également être observée au delà du lag 48. Ceci indique que l'erreur peut persister pendant plusieurs jours consécutifs. Pour traduire cette structure de corrélation, on évalue tout d'abord un modèle de type autorégressif d'ordre arbitrairement élevé. L'ordre 96 est ici choisi pour capturer la dépendance au delà du pic journalier. En rouge sont indiqués les coefficients d'autocorrélation d'une série artificielle générée selon ce modèle. Celui-ci disposant de 96 degrés de paramétrage,




FIG. 1. Autocorrélation des erreurs de prévision et des séries artificielles générées par les modèles étudiés.




FIG. 2. Nombre de franchissement d'une valeur seuil, pour la série originelle et pour les séries artificielles.

il parvient à reproduire la structure de corrélation présentant un pic journalier. Du fait de son nombre important de paramètres, sa vraisemblance annuelle de -4461 est pénalisée dans son critère BIC, établi à 9369 . Il convient de faire remarquer que des ordres encore plus élevés de modèles autorégressifs permettent d'atteindre de meilleures valeurs aussi bien quand à la vraisemblance qu'au BIC. On garde cependant ce modèle AR(96) comme référence de comparaison car il semble physiquement peu justifiable d'augmenter l'ordre au delà de quelques jours. De plus les analyses présentées dans la suite de cet article sont similaires pour cette famille de modèles. Concernant sa capacité à générer des données fidèles à la série originale, la figure 2 met en évidence une asymétrie de la série d'erreur de prévision : le nombre de franchissement d'un seuil décroît plus rapidement dans les valeurs positives que négatives. Le modèle AR(96) – comme fréquemment le cas pour des modèles autorégressifs – ne parvient pas à capturer cette asymétrie.

Ce premier modèle AR(96) ayant établi une première référence, on lui compare à présent des modèles ARMA qui utiliseraient un nombre de paramètres inférieur. Ceci pourrait potentiellement permettre une amélioration du critère BIC, même à vraisemblance égale. Le choix de l'ordre est réalisé en cherchant à minimiser le critère BIC, dont les variations sont indiquées sur le panneau supérieur de la figure 3. Un optimum apparaît à l'ordre $AR(5)$, $MA(5)$. Ce modèle ARMA(5,5) reflète bien la corrélation court terme – en jaune sur la figure 1 – mais s'éloigne de la série de référence dès quelques heures. De plus l'effet de périodicité journalière n'est pas naturellement capturée. Même ce modèle optimal parmi les ARMA est donc très en deçà de la performance d'un modèle AR(96), le nombre de paramètres ne parvenant pas à rattraper la mauvaise vraisemblance. Ces modèles ARMA ne parvenant pas non plus à capturer l'asymétrie des données artificielles, ils ne seront plus considérés dans la suite de l'étude.

A ce stade, deux directions d'amélioration peuvent donc être discutées : l'ajout d'une saisonnalité avec des modèles SARIMA et la dissociation de régimes avec des modèles MSAR.

1. Pour des raisons numériques, $\log(\mathcal{L})$ est ici préféré à $\mathcal{L}$.




FIG. 3. En haut : BIC des modèles ARMA en fonction des ordres autoregressifs et moyenne mobile. En bas : BIC des modèles SARIMA en fonction de l'ordre AR saisonnier et MA saisonnier. Ordres non saisonniers : AR(2), MA(2).

L'amélioration apportée par la saisonnalité est présentée sur le panneau inférieur de la figure 3. Du fait de la périodicité journalière, l'ordre de saisonnalité donnant les meilleures performances est naturellement 48 lags – soit une journée au pas de temps 30 min. Un optimum de BIC apparaît pour un modèle AR(2)MA(2), auquel s'ajoute un comportement saisonnier SAR(6)SMA(6). Ce modèle permet une réduction importante du nombre de paramètres à identifier puisqu'il comporte 16 coefficients et la variance. Il permet une réduction significative du BIC en comparaison des ARMA non saisonniers. Sa meilleure vraisemblance et son nombre de paramètres réduit lui permettent d'améliorer le BIC de référence du modèle AR(96). Sa structure d'autocorrélation est indiquée en violet sur la figure 1. Elle met en évidence le pic de saisonnalité, plutôt surestimé en l'occurrence. L'autocorrélation à très court terme est bien capturée, avant de sous-estimer les valeurs distantes d'environ une dizaine d'heures. Quand à la générations de données artificielles, la série générée présente bien une asymétrie notable, ce qui était une difficulté cruciale pour les modèles AR et ARMA non saisonniers. En revanche, l'occurrence des dépassements de valeurs proches de zéro est sous estimée. Les dépassements de valeurs proches de ± 1 sont quant à elles surestimées.

L'amélioration apportée par des régimes cachés dans un modèle AR(96) est à présent étudiée. Cet ordre est à nouveau retenu comme valeur de référence, ses performances étant représentative de cette famille de modèles. En effet, l'évolution du critère BIC en fonction de l'ordre du modèle autorégressif et du nombre d'états cachés est illustrée sur la figure 4. Elle met en évidence l'absence d'un optimum sur le BIC, que ce soit en termes d'ordre du modèle AR, ou en fonction du nombre




FIG. 4. Variations du BIC en fonction du nombre d'états cachés et de l'ordre du modèle AR.




FIG. 5. Premiers coefficients de chaque régime du modèle MS(5)AR(96), ainsi que sa matrice de transition.

de régimes cachés. Toutefois, les ordres supérieurs ne seront à nouveau pas étudiés, car la suite de cette contribution mettra en évidence leur manque de valeur ajoutée. La figure 5 illustre les coefficients des différents modèles autorégressifs du modèle MS(5)AR(96), tronqués aux 12 premières valeurs pour des raisons de lisibilité. La variété des modèles apparaît clairement, l'état 1 – en bleu – étant extrêmement bruité tandis que les états 2 – en rouge – et 4 – en violet – présentent des régimes intermédiaires. La matrice de transition également indiquée sur la figure 5 met cependant en lumière que certains états ont des probabilités d'apparition très faibles. La diagonale de cette matrice n'étant pas dominante, la stabilité et les chances d'occurrence de certains états sont fortement limitées. On fait donc le choix de ne pas augmenter au-delà l'ordre du modèle de Markov caché. Du fait de leur ordre AR élevé, ils conservent la capacité à prendre en compte le pic d'autocorrélation journalier, tout en étant particulièrement fidèles à plus court terme. Ces modèles MSAR sont les meilleurs sur ce critère parmi les modèles investigués présentés sur la figure 1. Concernant la fidélité de leurs données artificielles, ils présentent les mêmes qualités et limites que les modèles SARIMA : les valeurs proches de 0 sont sous-estimées au profit des valeurs plus élevées, alors que l'asymétrie est présente.

Pour conclure cette section de comparaison des modèles sur la base de leurs qualités statistiques, la figure 6 présente les scénarios proposés par ces différents modèles pour anticiper l'évolution de l'erreur de prévision – en vert sur la figure. L'instant considéré comme actuel est matérialisé par une verticale verte. On choisit ici un instant où l'erreur est particulièrement importante. Bien que de telles circonstances soient rares, elle permet d'illustrer les spécificités de chaque modélisation. Dans ce but, on ajoute ici le modèle le plus simple – autorégressif d'ordre 1 – qui sera également utilisé au cours de la section 3. Sur le panneau supérieur, ce modèle permet en effet de générer des scénarios cohérents mais qui manquent la périodicité journalière de la série : la forte fluctuation aux alentours de 10 h n'est pas anticipée. De plus la variance des scénarios est particulièrement élevée. La comparaison avec un modèle AR(96) permet naturellement d'améliorer ces deux points. La saisonnalité est anticipée et la variance des scénarios est réduite à court terme. Lorsque l'horizon d'anticipation s'éloigne en revanche – typiquement à partir de 72 h sur la figure 6 – ces deux modèles tendent à se ressembler. Le panneau inférieur représente quant à lui les données générées par un modèle SARIMA qui continuent à long terme à capturer la forte fluctuation quotidienne. La variance des scénarios est nettement inférieure à celle de tous les autres modèles présentés. Ce modèle a tendance à proposer une variance très faible et fournit donc un ensemble restreint de scénarios. Cela devrait en faire un modèle de prévision de haute qualité, tant pour le futur proche que pour le long terme. Sur le long terme, cette faible variance permet d'atteindre des valeurs de BIC intéressantes. Cependant, quel que soit l'horizon, la réalisation peut ne pas être incluse dans l'ensemble des scénarios proposés. Son manque de variance s'avère alors être un défaut, qui peut lui être




FIG. 6. Exemple de série temporelle d'erreurs de prévision de la consommation, en vert, et de prévisions générées par différents modèles. L'heure actuelle est indiquée par une ligne verticale verte. Ligne continue : moyenne des scénarios. Zone colorée : variance $\pm$. En bas : État le plus probable du modèle MSAR.

préjudiciable dans certaines circonstances. La section 3 confirmera que cela est contre-productif pour l'application de contrôle optimal stochastique. Le modèle MSAR est unique en ce sens qu'il indique l'état caché qui lui semble le plus probable. Cette succession est indiquée au bas du panneau inférieur par une succession de couleurs, correspondant à l'état le plus probable selon les probabilités de lissage. La succession de couleurs révèle que l'état violet (état 4 selon la figure 5) est le plus fréquent. Il est associé à une forte volatilité, visible autour de -12 h. L'état vert (état 5) est le deuxième plus fréquent. L'apparition récurrente de ces deux états est cohérente avec la matrice de transition. Bien que leur structure de corrélation soit différente, ces deux états semblent visuellement proches au sein d'une série réelle. Leur interprétabilité est donc malheureusement limitée, d'où le choix de ne pas présenter des résultats pour des ordres supérieurs.

Les modèles SARIMA et MSAR semblent donc offrir des améliorations complémentaires, en termes de vraisemblance pour le premier et de structure de corrélation pour le second.

3. APPLICATION À UN PROBLÈME DE CONTRÔLE OPTIMAL

Après la validation *quality based* de la section précédente, on cherche ici une évaluation *objective based* du service rendu par les modèles d'erreur de prévision [17]. En effet, la modélisation n'a pas de valeur en soi. Sa valeur réside dans les améliorations qu'elle permettra d'apporter lorsqu'elle sera utilisée dans le cadre d'un processus plus large.

3.1. Définition du problème et résolution

Afin d'aller plus loin que la validation statistique présentée dans la section 2, l'objectif de cette section est de mettre en évidence dans un problème représentatif qu'une meilleure modélisation de l'erreur de prévision peut permettre une meilleure gestion, sans toutefois la garantir. Les scénarios d'évolution des erreurs de prévision peuvent être utilisés dans tout problème d'optimisation stochastique, tel que la gestion de problèmes réels, documentés par les données ouvertes des opérateurs de marché. Néanmoins, afin de préserver l'interprétabilité des résultats, un problème académique simple est ici considéré. Ce problème illustratif est donc la gestion d'une batterie qui doit compen-




FIG. 7. Cas d'étude considéré : le réseau fournit la consommation électrique mais les écarts à la prévision sont pénalisés. Un stockage est alors utilisé pour atténuer optimalement les erreurs de prévision.

ser les erreurs de prévision, comme le montre la figure 7. La consommation est supposée être fournie par un réseau extérieur. Le coût de cette fourniture est en dehors du périmètre de cette étude. En revanche la prévision de consommation est supposée être transmise au réseau. Celui-ci pénalisera donc les déviations par rapport à ce profil transmis. Ceci pourrait traduire les surcoûts occasionnés par ces écarts qui nécessitent opérationnellement l'appel à des marchés intrajournaliers, voire à des capacités de réserve. Un stockage est alors ajouté pour tenter de compenser au mieux possible les écarts entre la prévision de consommation et la puissance réellement appelée depuis le réseau. Le coût associé à ce problème illustratif est supposé quadratique. Cette hypothèse est tout à fait méthodologique à ce stade, l'objectif principal étant de comparer les modèles entre eux. Un coût linéaire n'étant pas strictement convexe, il aurait pu conduire à plusieurs trajectoires de contrôle aboutissant à la même valeur de fonction objectif. Outre la garantie d'une stricte convexité, un coût quadratique permet de plus fortement pénaliser les erreurs importantes. Dans une application réelle, celles-ci auraient été les plus coûteuses car nécessitant de mobiliser des centrales additionnelles, aux coûts marginaux plus élevés. Le problème de contrôle optimal prend donc la forme suivante :

$$\min_{P_{sto}(t)} \mathbb{E}_{\Delta P} \left\{ \sum_{\tau=t}^{\infty} (\Delta P^{\tau} - P_{sto}^{\tau})^2 \right\} \quad (4a)$$

$$\text{subject to, } \forall t, \forall \tau, \quad 0 \leq E_{sto} \leq \overline{E_{sto}} \quad (4b)$$

$$E_{sto}(t + \Delta T) = E_{sto}(t) + \Delta T \cdot P_{sto} \quad (4c)$$

où P_{sto} désigne la puissance échangée par la batterie – comptée positivement lors d'une charge. Les puissances minimales et maximales de la batterie ne sont pas prises en compte ici, à nouveau puisque l'étude se focalise sur l'impact des modèles d'erreur de prévision. L'énergie maximale stockable est notée $\overline{E_{sto}}$. Ce paramètre de dimensionnement sera discuté en relation avec le modèle d'erreur choisi. Enfin l'équation (4c) est l'équation dynamique régissant l'énergie stockée. A nouveau elle est ici considérée sous sa forme la plus simple puisqu'un modèle détaillé de la batterie n'impacte que marginalement une comparaison des modèles dynamiques de l'erreur de prévision.

Ce problème est ici résolu à l'aide d'un Model Predictive Control MPC stochastique [18]. Le choix de cette méthode est motivé par sa capacité intrinsèque à prendre en charge des problèmes dynamiques stochastiques, de manière optimale lorsque l'horizon d'optimisation est suffisamment long. Dans le cas présent, la performance de la gestion converge vers une valeur optimale pour une fenêtre d'optimisation de 120 h, quelque soit la capacité de stockage considérée par la suite. De plus, l'objectif de cette contribution est de pouvoir comparer les performances de gestion basées sur des modèles d'anticipation différents. Afin de permettre cette comparaison sur des bases similaires, à chaque instant connaissant les observations passées, chaque modèle fournira des prévisions sous la forme de $N = 50$




FIG. 8. Évolution du coût annuel normalisé en fonction de la capacité de stockage, selon diverses modélisations de l'erreur de prévision.

scénarios d'évolution de l'erreur de prévision de consommation. Ces scénarios sont utilisés pour évaluer l'espérance de (4) et pour calculer la puissance stockée optimale P_{sto}^* . Il est donc nécessaire d'adopter une méthode de contrôle capable de gérer une prévision sous la forme d'un ensemble de scénarios.

3.2. Résultats et discussion

Les performances de gestion obtenues selon les différents modèles d'erreur de prévision sont représentées sur la figure 8. Tout d'abord la courbe bleue représente l'évolution du coût annuel en fonction de la capacité de stockage lorsqu'un contrôle myope est appliqué. Celui-ci compense parfaitement l'erreur de prévision, jusqu'à saturation du stockage. La série d'erreur de prévision étant normalisée – $\sigma = 1$ – la capacité de stockage l'est également : $E_{sto} = 1$ signifie que le stockage pourrait atténuer pendant 1 h une erreur d'amplitude σ . Le coût annuel est quant à lui normalisé par sa valeur en l'absence de stockage. Naturellement ce coût diminue lorsque la capacité de stockage est augmentée. On constate cependant que la valeur ne tend pas encore vers zéro, malgré l'ajout d'une capacité conséquente allant jusqu'à 100. En effet une saisonnalité annuelle peut être observée sur les données. L'erreur de prévision est légèrement positive pendant l'hiver et le printemps, avant d'être légèrement négative pendant l'été et l'automne. On rappelle qu'il s'agit ici d'une série normalisée à moyenne nulle construite sur des données brutes. Cette tendance à l'échelle de plusieurs mois nécessiterait donc des capacités de stockage encore plus importantes pour être parfaitement compensées. Dans le cadre de cette étude méthodologique, l'analyse n'est cependant pas perturbée par cette tendance – donc l'élucidation est en dehors du périmètre de cette contribution. En ajoutant un modèle aussi simple qu'un AR(1), une amélioration notable des performances de gestion peut être constatée. Cette amélioration est très limitée pour les capacités de stockage faibles – ~ 3 . En effet le stockage étant presque immédiatement saturé, la marge de manœuvre possible pour la gestion est réduite. En revanche une amélioration notable est ensuite observée, qui asymptotiquement tend vers une réduction constante lorsque la capacité augmente. Le second modèle investigué est un AR(96). Ce modèle permettant de traduire fidèlement la structure de corrélation de la série d'erreur de prévision, il est cohérent qu'il apporte également une amélioration très notable de la performance de gestion. Les améliorations apportées par ce modèle AR(96) sont supérieures dans leurs valeurs à celles du modèle AR(1), mais similaires dans leurs allures : l'amélioration est limitée pour les tout petits stockages, avant de tendre vers une réduction constante. Enfin, les performances du modèle SARIMA sont présentées en violet. Contrairement aux autres modèles où une qualité statistique se traduisait en une qualité applicative, le modèle SARIMA ne parvient pas à transposer sa bonne vraisemblance dans des performances de gestion. Il peut paradoxalement s'avérer pire qu'un contrôle myope pour des stockages de taille limitée. Ceci peut être ex-

pliqué par la tendance de ce modèle à sous estimer la variance de la série et à produire des ensembles de scénarios qui manqueront la réalisation réelle, même à court terme. Un exemple de ce comportement peut être observé sur la figure 6, aux alentours de l'heure 6. Les performances obtenues sont cependant très dépendantes de la taille du stockage. De plus grands stockages parviennent à améliorer leur gestion, sans doute parce qu'ils sont en mesure d'utiliser les anticipations à long terme fournies par le modèle SARIMA. Enfin, le MSAR ne parvient pas à transférer sa supériorité en termes de probabilité à une gestion significativement meilleure par rapport à l'AR(96).

4. CONCLUSION ET PERSPECTIVES

Cette contribution s'est focalisée sur la modélisation dynamique de l'erreur de prévision de consommation électrique. Ces erreurs étant inhérentes à l'exercice d'anticipation, on s'est ici attaché à l'étude de leur structure temporelle. Des modèles de type série temporelle ont été investigués afin de conserver une interprétabilité des résultats. Une forte autocorrélation à court terme, ainsi qu'une périodicité journalière a été remarquée. Les modèles autorégressifs d'ordre élevés sont en mesure de les traduire. Ils peuvent être améliorés grâce à l'ajout d'une saisonnalité ou bien d'un modèle de Markov caché. La valeur de ces modèles a également été quantifiée selon une approche *objective based*, en les insérant dans un problème de contrôle optimal visant à compenser les erreurs à l'aide d'un stockage. La valeur ajoutée des modèles les plus avancés apparut alors limitée, si ce n'est contre-productive.

À l'issue de cette étude préliminaire concernant la modélisation des erreurs de prévision de consommation, de nombreuses perspectives sont ouvertes. Tout d'abord la valeur des modèles qui se sont révélés les plus adéquats devrait être éprouvée sur des problèmes plus réalistes et complexes. Leur utilisation au sein de marchés de l'électricité intrajournalier semble prometteuse. De plus on a ici uniquement étudié la prévision J-1. Non seulement une étude similaire pourrait être réalisée sur la prévision intrajournalière, mais elle mériterait de plus de considérer la prévision précédente comme covariable explicative. L'erreur de prévision J-1 permettrait possiblement de mieux anticiper l'erreur résiduelle intrajournalière. Ce dernier point ouvre également la perspective d'ajouter d'autres covariables au modèle, comme des erreurs de prévision météorologiques qui contribuent aux aléas de la consommation. Enfin d'autres types de modèles pourraient être investigués. L'accent fut ici mis sur des modèles de séries temporelles afin de conserver l'interprétabilité et de pouvoir mieux discuter l'ordre le plus adapté. Cela appelle néanmoins un benchmark entre plusieurs types de modélisation (LSTM, GARCH, ...). A nouveau un tel benchmark nécessiterait non seulement d'être mené selon une approche *quality based*, mais également en *objective based*, les deux ne menant pas nécessairement aux mêmes conclusions ainsi que cela fut montré ici.

5. RÉFÉRENCES

- [1] I. K. Nti, M. Teimeh, O. Nyarko-Boateng, and A. F. Adekoya, "Electricity load forecasting : a systematic review," *Journal of Electrical Systems and Information Technology*, vol. 7, pp. 1–19, 2020.
- [2] P. Pinson, C. Chevallier, and G. N. Kariniotakis, "Trading wind generation from short-term probabilistic forecasts of wind power," *IEEE transactions on Power Systems*, vol. 22, no. 3, pp. 1148–1156, 2007.
- [3] C. Lowery and M. O'Malley, "Impact of wind forecast error statistics upon unit commitment," *IEEE Transactions on Sustainable Energy*, vol. 3, no. 4, pp. 760–768, 2012.
- [4] R. Doherty and M. O'malley, "A new approach to quantify reserve demand in systems with significant installed wind capacity," *IEEE Transactions on Power Systems*, vol. 20, no. 2, pp. 587–595, 2005.
- [5] A. Fabbri, T. G. Roman, J. R. Abbad, and V. M. Quezada, "Assessment of the cost associated with wind generation prediction errors in a liberalized electricity market," *IEEE Transactions on Power Systems*, vol. 20, no. 3, pp. 1440–1446, 2005.

- [6] K. Mahmud, J. Ravishankar, M. Hossain, and Z. Y. Dong, "The impact of prediction errors in the domestic peak power demand management," *IEEE Transactions on Industrial Informatics*, vol. 16, no. 7, pp. 4567–4579, 2019.
- [7] P. Piotrowski, I. Rutyna, D. Baczyński, and M. Kopyt, "Evaluation metrics for wind power forecasts : A comprehensive review and statistical analysis of errors," *Energies*, vol. 15, no. 24, p. 9657, 2022.
- [8] D. W. Van der Meer, J. Widén, and J. Munkhammar, "Review on probabilistic forecasting of photovoltaic power production and electricity consumption," *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 1484–1512, 2018.
- [9] H. Hersbach, "Decomposition of the continuous ranked probability score for ensemble prediction systems," *Weather and Forecasting*, vol. 15, no. 5, pp. 559–570, 2000.
- [10] R. L. G. Latimier, E. Le Bouedec, and V. Monbet, "Markov switching autoregressive modeling of wind power forecast errors," *Electric Power Systems Research*, vol. 189, p. 106641, 2020.
- [11] P. Haessig, B. Multon, H. B. Ahmed, S. Lascaud, and P. Bondon, "Energy storage sizing for wind power : impact of the autocorrelation of day-ahead forecast errors," *Wind Energy*, vol. 18, no. 1, pp. 43–57, 2015.
- [12] R. Le Goff Latimier, "Source code repository," <https://gitlab.com/satie.sete/dynamic-modeling-forecast-errors-electric-consumption>, 2025, [Online].
- [13] P. E. de Mello, N. Lu, and Y. Makarov, "An optimized autoregressive forecast error generator for wind and load uncertainty study," *Wind Energy*, vol. 14, no. 8, pp. 967–976, 2011.
- [14] M. Olsson and L. Soder, "Modeling real-time balancing power market prices using combined sarima and markov processes," *IEEE Transactions on Power Systems*, vol. 23, no. 2, pp. 443–450, 2008.
- [15] A. K. Dubey, A. Kumar, V. García-Díaz, A. K. Sharma, and K. Kanhaiya, "Study and analysis of sarima and lstm in forecasting time series data," *Sustainable Energy Technologies and Assessments*, vol. 47, p. 101474, 2021.
- [16] P. Ailliot and V. Monbet, "Markov-switching autoregressive models for wind time series," *Environmental Modelling & Software*, vol. 30, pp. 92–101, 2012.
- [17] A. Stratigakos, A. Michiorri, and G. Kariniotakis, "A value-oriented price forecasting approach to optimize trading of renewable generation," in *2021 IEEE Madrid PowerTech*. IEEE, 2021, pp. 1–6.
- [18] P. Kou, F. Gao, and X. Guan, "Stochastic predictive control of battery energy storage for wind farm dispatching : Using probabilistic wind power forecasts," *Renewable Energy*, vol. 80, pp. 286–300, 2015.