

Prévision de la production intrajournalière d'un ensemble de systèmes photovoltaïques par réseaux de neurones récurrents et variables exogènes physiques

Pierrick Bruneau*, David Fiorelli*, Christian Braun*, Daniel Koster*

* LIST, Esch-sur-Alzette, Luxembourg
prenom.nom@list.lu,
<http://www.list.lu>

Résumé. Des prévisions intrajournalières précises de la production des systèmes photovoltaïques (PV) sont cruciales pour améliorer le fonctionnement des réseaux de distribution d'énergie. Nous présentons un modèle autorégressif connexionniste s'appuyant pour cette tâche sur un modèle physique et déterministe de performance de panneaux PV. Notre approche utilise les sorties du modèle physique comme variables exogènes et traite les données de plusieurs sites avec un seul modèle. Nous introduisons une distribution gaussienne tronquée en sortie et utilisons l'invariance d'échelle du modèle pour traiter implicitement les effets saisonniers. Nous validons l'intérêt de l'approche sur des données réelles.

1 Introduction

Les systèmes photovoltaïques (PV) gagnent en importance dans les réseaux de distribution d'énergie modernes, mais leur nature intermittente, due aux fluctuations météorologiques, pose des défis aux gestionnaires de réseaux de distribution (GRD). Des prévisions intrajournalières précises de la production PV sont cruciales pour relever ces défis. De plus, de nombreux modèles fournissent des prévisions ponctuelles, sans caractériser l'incertitude associée, alors que cette information peut être critique pour un GRD afin de quantifier et atténuer les risques dans le cadre d'une stratégie commerciale. La production PV peut être prédite en modélisant la physique des panneaux pour un rayonnement solaire donné (Koster et al., 2019). Ces modèles s'appuient donc sur des prévisions issues de services météorologiques. Cependant, ils peuvent ne pas capturer des effets locaux ou les caractéristiques spécifiques des systèmes influençant la production effective. Cet article présente un modèle neuronal autorégressif pour des prévisions probabilistes intrajournalières de production PV, exploitant les sorties d'un modèle physique (Koster et al., 2019) dans un contexte d'apprentissage automatique. Les principales contributions sont : 1) l'intégration d'une composante gaussienne tronquée en sortie du modèle DeepAR et 2) l'implémentation d'une approche hybride-physique utilisant les prévisions du modèle physique comme variables exogènes. Nous fournissons une évaluation expérimentale détaillée, incluant une étude d'ablation et des comparaisons avec des modèles de la littérature. Nos résultats illustrent comment cette approche atténue les effets locaux impactant le modèle de performance physique existant, atteignant un *skill score* de 15,72% par rapport au modèle

physique de référence. Ce travail applicatif a été publié dans *Neural Computing and Applications* (Bruneau et al., 2024).

2 Travaux connexes

Afin de positionner notre travail, dans la Section 2.1, nous discutons d'abord des méthodes dédiées à la prévision de production PV ainsi que des modèles de séries temporelles pouvant être adaptés à l'application. Ensuite, dans la Section 2.2, nous examinons les caractéristiques distinctives de la structure des prédictions et de la validation dans le contexte de l'apprentissage automatique pour les séries temporelles, qui sont cruciales dans notre contexte expérimental.

2.1 Prévision de production PV et modèles de prédiction de séries temporelles

La prévision de production PV suit généralement une approche en deux étapes : prédire le rayonnement solaire, puis le convertir en prédictions de production PV (Blaga et al., 2019; Koster et al., 2019). La littérature inclut aussi des modèles statistiques (Elsinga et van Sark, 2017) et d'apprentissage automatique, allant des modèles de persistance aux approches plus complexes comme les réseaux de neurones multi-couches (Inman et al., 2013). Les récentes avancées en apprentissage profond ont conduit au développement de modèles plus sophistiqués pour la prédiction des séries temporelles. L'architecture *Long Short-Term Memory* (LSTM) (Hochreiter et Schmidhuber, 1997) et ses variantes restent populaires grâce aux améliorations des procédures d'entraînement et au mécanisme encodeur-décodeur.

Le modèle DeepAR (Salinas et al., 2020) implémente une prévision flexible pour les séries temporelles univariées, définissant un intervalle de contexte et un intervalle de prévision, et est optimisé de bout en bout par rapport à toute la plage de prévision. Cela contraste avec les modèles linéaires comme ARIMA, qui sont optimisés pour des prévisions au pas de temps suivant. DeepAR prédit des paramètres probabilistes utilisés pour générer des prévisions et prend en charge l'utilisation de variables exogènes, le rendant adapté à notre approche hybride-physique. Bien que certaines études aient appliqué l'apprentissage profond à la prédiction de production PV (Abdel-Nasser et Mahmoud, 2019; Wang et al., 2020), elles se concentrent souvent sur des scénarios spécifiques ou des prévisions agrégées. Notre approche vise à traiter plusieurs sites PV avec un seul modèle, incorporant les prévisions du modèle physique comme variables exogènes pour améliorer les capacités prédictives (Rasul et al., 2021).

2.2 Structure des prédictions et validation

La prédiction de séries temporelles emploie deux stratégies principales : les prédictions périodiques et les prédictions glissantes (Figure 1). Notre travail se concentre sur les prédictions périodiques en raison de la dépendance aux prévisions météorologiques, émises à heure fixe dans la journée. Les données sont supposées horaires dans le reste de l'article.

La validation dans le contexte des séries temporelles est difficile en raison de la structure séquentielle des données. Les méthodes traditionnelles de validation croisée supposant l'indépendance des données ne sont pas applicables (Bergmeir et Benítez, 2012). Parallèlement, l'évaluation classique à origine fixe (e.g., une sous-séquence est généralement extraite de la fin

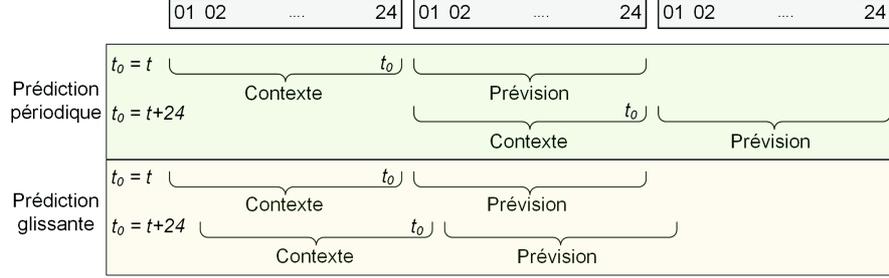


FIG. 1 – Distinction entre prédictions périodiques et glissantes. t_0 désigne le pas de temps associé à l'échantillon traité.

de la série temporelle en tant qu'échantillon de test dans les compétitions) est problématique si les séries temporelles ne sont pas stationnaires. Pour résoudre ce problème, nous utilisons des blocs temporels entrelacés mais disjoints pour l'entraînement, la validation et le test. Cette approche aide à atténuer le surapprentissage, fournit des estimations de performance plus fiables et une meilleure généralisation pour notre modèle basé sur l'apprentissage profond.

3 Modèle DeepAR et vraisemblance gaussienne positive

Sur la base de notre revue de littérature, nous avons choisi le modèle DeepAR (Salinas et al., 2020) comme cadre pour notre implémentation, adaptant l'implémentation officielle (Alexandrov et al., 2020) à nos besoins. Bien que des approches de prédiction multivariées comme DeepVAR (Salinas et al., 2019) aient été envisagées, nous avons opté pour un modèle univarié avec les informations du site PV comme variables exogènes. Ce choix permet une gestion plus flexible des prédictions du modèle physique, des valeurs manquantes, et une généralisation plus aisée à de nouveaux sites PV. Le modèle DeepAR, illustré dans la Figure 2, est défini par un produit de facteurs de vraisemblance :

$$Q_{\Theta} = \prod_{n=1}^N \prod_{t=t_0+1}^T p(z_{n,t} | \theta(\mathbf{h}_{n,t}, \Theta)) \quad (1)$$

où N est le nombre de séries temporelles d'apprentissage, T la taille de chaque série, t_0 défini selon la Figure 1, et $\mathbf{h}_{n,t}$ la variable d'état obtenue de manière récursive à partir d'un modèle LSTM Θ conditionné par les variables observées ($z_{n,t-1}$) et exogènes ($\mathbf{X}_{n,t}$). Comme les mesures de puissance PV sont nécessairement des nombres réels non négatifs, une contribution de cet article est de permettre à la distribution gaussienne d'être tronquée par le bas à 0 (la limite supérieure restant $+\infty$) dans le contexte du modèle DeepAR :

$$p(z_{n,t} | \theta_{\mu}, \theta_{\sigma}) = \frac{1}{\sigma \sqrt{2\pi}} \frac{\exp\left(-\frac{1}{2} \frac{(z_{n,t} - \theta_{\mu})^2}{\theta_{\sigma}^2}\right)}{1 - \Phi\left(-\frac{\theta_{\mu}}{\theta_{\sigma}}\right)} \quad (2)$$

où Φ est la fonction de répartition de la loi gaussienne standard. Les dernières couches de Θ servent à la génération des paramètres de la distribution, et les prévisions sont obtenues par

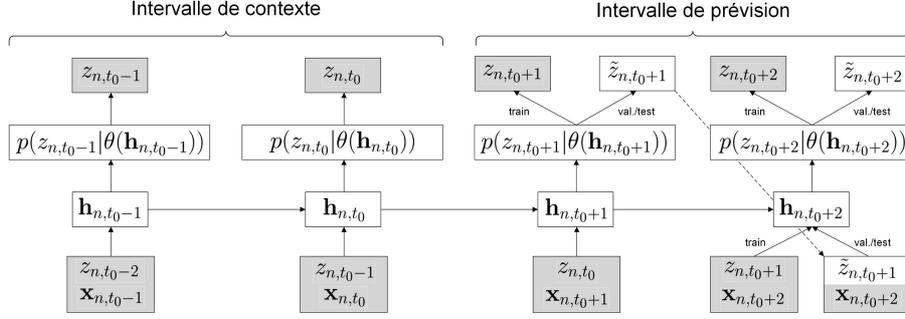


FIG. 2 – Illustration du modèle DeepAR. Les variables observées sont représentées par des boîtes grises, et les variables latentes par des boîtes blanches. Pour l'intervalle de contexte, les variables z sont toujours connues. Pour l'intervalle de prévision, le modèle se comporte différemment en phase d'entraînement et de test. En phase de test, les variables \tilde{z} sont échantillonnées selon p , formant des chemins d'échantillonnage. Les lignes pleines représentent les dépendances entre variables aléatoires, et les lignes pointillées soulignent les échantillons réinjectés.

échantillonnage (voir Figure 2). Les échantillons sont générés en utilisant la transformation de Smirnov :

$$\tilde{z} = \Phi^{-1} \left(\Phi \left(-\frac{\theta_\mu}{\theta_\sigma} \right) + \tilde{u} \left(1 - \Phi \left(-\frac{\theta_\mu}{\theta_\sigma} \right) \right) \right) \theta_\sigma + \theta_\mu \quad (3)$$

où \tilde{u} est un échantillon uniforme dans $[0, 1]$.

4 Expériences

4.1 Données et méthodologie

Notre étude prédit la production PV horaire pour 119 systèmes au Luxembourg de 2020 à 2021. Nous utilisons les séries de mesures de production PV, ainsi que les prévisions intrajournalières associées par le modèle physique. Nous disposons également de descripteurs continus des systèmes : parmi leurs spécifications, nous avons retenu les éléments suivants pour leur pertinence quant aux courbes de puissance PV : l'exposition du système (degrés), son inclinaison (degrés), sa puissance nominale (W) et son facteur de calibration (sans unité, lié à l'installation sur site). DeepAR facilite la gestion des systèmes de dimensionnement variable (1,4kW à 247kW) en normalisant les mesures et les sorties du modèle physique par la valeur absolue moyenne de l'intervalle de contexte pour chaque échantillon indépendamment, implémentant une invariance d'échelle *ad hoc*. Il permet aussi la prise en compte de variables exogènes catégorielles ou continues, dynamiques (ici, prévisions du modèle physique et variables calendaires pour la saisonnalité) qui diffèrent pour chaque t , ou statiques (descripteurs et identifiants des systèmes), constantes à n donné. Nous construisons des échantillons avec

48h de contexte et 24h de prévision en les découpant selon l’approche périodique décrite en Figure 1. Les métriques de performance incluent le RMSE normalisé (*Root Mean Square Error*, nRMSE) et le MAE normalisé (*Mean Absolute Error*, nMAE). La normalisation est effectuée en utilisant la puissance nominale respective des systèmes PV. Le *skill score* mesure l’amélioration relative du nMAE par rapport au modèle physique, choisi en tant que *baseline* en Section 4.2. Nous considérons également le CRPS (*Continuous Ranked Probability Score* - voir, par exemple, (Gasthaus et al., 2019)), une mesure sans unité qui calcule en substance le nMAE pour un continuum de quantiles simultanément. Nous excluons les périodes nocturnes (angle zénithal $> 85^\circ$) des calculs de métriques.

Notre schéma de validation prend en compte le risque de fuite d’information dû à la forte corrélation entre les systèmes en regroupant les échantillons par coordonnées temporelles et en les divisant en blocs de deux semaines pour l’entraînement, la validation et le test. Nous sélectionnons aléatoirement 60% des blocs pour l’entraînement, et les 40% restants pour la validation et le test, en excluant les recouvrements induits par le découpage. Nous séparons ces 40% de manière totalement aléatoire afin que l’ensemble de validation soit représentatif de l’ensemble de test : le risque est alors limité car les données de validation ne servent que pour l’arrêt précoce de l’apprentissage, et n’influencent pas les paramètres du modèle. On a alors 40670 échantillons d’entraînement, 13498 de validation et 13498 de test. Les modèles ont été entraînés en utilisant l’algorithme Adam (taux d’apprentissage 10^{-3} , taille de batch 64, 200 epochs) avec arrêt précoce basé sur le nMAE de validation. Nous avons optimisé la taille de la couche cachée LSTM (40) et le nombre de composantes de mélange (5). Notre étude d’ablation commence par le *modèle 1*, la meilleure variante (gaussienne positive, variables physiques, ID du système). Les *modèles 2-3* utilisent des distributions gaussiennes classiques et Student au lieu de la gaussienne positive. Le *modèle 4* utilise les descripteurs de systèmes au lieu des identifiants. Le *modèle 5* n’utilise aucune information spécifique aux systèmes. Le *modèle 6* utilise une seule composante gaussienne positive. Le *modèle 7* n’utilise aucune variable exogène physique. Le *modèle 8* est MQCNN (Wen et al., 2018), le *modèle 9* ISSM (Seeger et al., 2016), et le *modèle 10* le réseaux de neurones multi-couches (MLP), ce dernier sans variable exogène, ni descripteur de système ou ni physique. En tant que *baseline*, nous rapportons également les résultats des modèles de persistance, NPTS (Gasthaus, 2016) et Prophet (Taylor et Letham, 2018).

4.2 Résultats et discussion

Le Tableau 1 présente nos résultats expérimentaux. Le modèle physique sert de référence principale pour les calculs de *skill score*. Notre meilleur modèle atteint une amélioration du *skill score* de 15,72% par rapport au modèle physique. La composante gaussienne positive apporte une petite mais significative amélioration. L’utilisation de l’identifiant de système est préférable aux descripteurs continus. L’écart de performance le plus important se produit lorsqu’on ignore les variables exogènes du modèle physique, ce qui valide la pertinence de l’approche proposée. La Figure 3 illustre comment notre modèle atténue automatiquement les effets locaux pour un système problématique. Le modèle neuronal ignore efficacement le décalage systématique du modèle physique (causé par un toit à double pente) et fournit des prédictions sensées avec des intervalles de *prédiction* (i.e., reflétant la variance des prédictions - à distinguer de l’intervalle de *prévision* introduit en Section 2.1) appropriés. Ces résultats

ID	Description	nRMSE (%)	nMAE (%)	Skill (%)	CRPS
<i>Baselines</i>					
-	Physique	11.396	7.958	-	-
-	Persistence	16.258	10.117	-27.1	-
-	NPTS	14.437 (01)	9.039 (01)	-13.6	-
-	Prophet	18.189 (02)	10.152 (02)	-27.6	-
<i>Modèles</i>					
1	Meilleur	10.808 (82)	6.707 (69)	15.72	4.816 (48)
2	gaussienne	10.950 (31)	6.844 (70)	14.00	4.897 (48)
3	Student	10.928 (82)	6.841 (47)	14.04	4.916 (39)
4	Sans ID système	11.127 (102)	6.966 (49)	12.47	5.007 (38)
5	Sans descripteurs	11.461 (100)	7.292 (67)	8.37	5.278 (50)
6	Sans descr. ni mélange	11.547 (42)	7.711 (17)	3.10	5.676 (24)
7	Sans modèle physique	14.203 (106)	9.333 (53)	-17.28	6.577 (32)
8	MQCNN	11.040 (101)	7.249 (31)	8.91	5.259 (24)
9	ISSM	12.209 (18)	8.061 (20)	-1.29	6.231 (02)
10	MLP	14.687 (69)	10.087 (33)	-26.75	7.522 (37)

TAB. 1 – Métriques de test nRMSE, nMAE, skill score et CRPS. Les meilleurs résultats sont en gras. Les valeurs entre parenthèses sont les écarts-types ($\times 10^{-3}$).

démontrent l’efficacité de notre approche pour améliorer les prédictions de production PV, en particulier pour gérer les systèmes atypiques.

5 Conclusion et perspectives

Nous avons développé un modèle neuronal autorégressif qui améliore un modèle de performance physique déjà performant pour les prédictions de production PV intrajournalières. Notre meilleure configuration utilise les prédictions du modèle de performance PV comme variables exogènes, un mélange de gaussiennes positives comme distribution de sortie, et une variable catégorielle statique identifiant le système. Cette approche modélise efficacement les effets locaux et le profil de données en forme de cloche typique des applications d’énergie solaire. Les travaux futurs exploreront des méthodes de régression par quantiles récentes, étudieront des techniques pour ajouter de nouveaux systèmes sans réentraînement complet du modèle, et envisageront des intervalles de prévision plus longs. Nous prévoyons également d’aborder les problèmes de glissement de domaine typiques des séries temporelles en impliquant potentiellement des techniques issues de la littérature sur l’adaptation de domaine (Redko et al., 2019) et des techniques explicables (Rojat et al., 2021).

5.1 Remerciements

Cette recherche a été financée par le Fonds National de la Recherche du Luxembourg (FNR) dans le cadre du projet FNR BRIDGES *CombiCast* (BRIDGES18/IS/12705349/Combi-Cast). De plus, les auteurs tiennent à remercier notre partenaire Electric (une marque de Hoffmann Frères Energie et Bois SARL), pour sa confiance et sa contribution au projet, tant financièrement qu’en termes de main-d’oeuvre et de données.

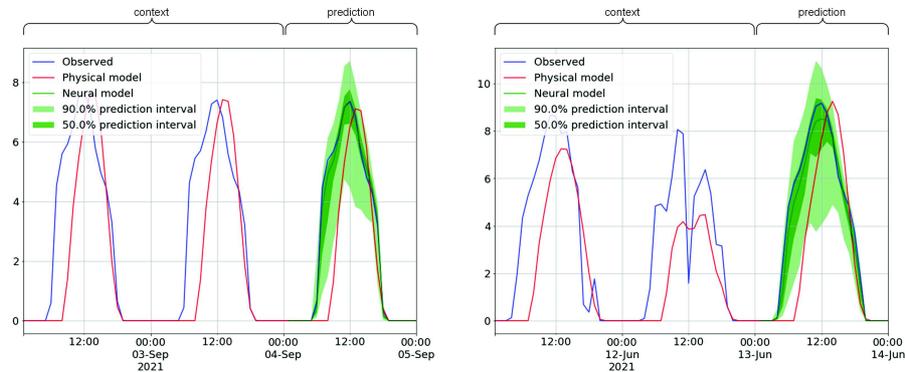


FIG. 3 – Deux échantillons de test associés au système 44. Les intervalles de prédiction sont affichés en nuances de vert. Les observations et les prédictions du modèle physique intrajournalier sont respectivement en bleu et en rouge.

Références

- Abdel-Nasser, M. et K. Mahmoud (2019). Accurate photovoltaic power forecasting models using deep LSTM-RNN. *Neural Computing and Applications* 31(7), 2727–2740.
- Alexandrov, A., K. Benidis, M. Bohlke-Schneider, V. Flunkert, J. Gasthaus, T. Januschowski, D. C. Maddix, S. Rangapuram, D. Salinas, J. Schulz, L. Stella, A. C. Türkmen, et Y. Wang (2020). GluonTS : Probabilistic and Neural Time Series Modeling in Python. *Journal of Machine Learning Research* 21(116), 1–6.
- Bergmeir, C. et J. M. Benítez (2012). On the use of cross-validation for time series predictor evaluation. *Information Sciences* 191, 192–213.
- Blaga, R., A. Săbăduș, N. Ștefu, C. Dughir, M. Paulescu, et V. Bădescu (2019). A current perspective on the accuracy of incoming solar energy forecasting. *Progress in energy and combustion science* 70, 119–144.
- Bruneau, P., D. Fiorelli, C. Braun, et D. Koster (2024). Forecasting intraday power output by a set of PV systems using recurrent neural networks and physical covariates. *Neural Computing and Applications* 36(31), 19515–19529, doi: 10.1007/s00521-024-10257-4.
- Elsinga, B. et W. van Sark (2017). Short-term peer-to-peer solar forecasting in a network of photovoltaic systems. *Applied Energy* 206, 1464–1483.
- Gasthaus, J. (2016). Non-parametric time series forecaster. Technical Report, Amazon.
- Gasthaus, J., K. Benidis, Y. Wang, S. Rangapuram, D. Salinas, V. Flunkert, et T. Januschowski (2019). Probabilistic Forecasting with Spline Quantile Function RNNs. In K. Chaudhuri et M. Sugiyama (Eds.), *International Conference on Artificial Intelligence and Statistics*, pp. 1901–1910.
- Hochreiter, S. et J. Schmidhuber (1997). Long short-term memory. *Neural Computation* 9(8), 1735–1780.

- Inman, R. H., H. T. C. Pedro, et C. F. M. Coimbra (2013). Solar forecasting methods for renewable energy integration. *Progress in Energy and Combustion Science* 39(6), 535–576.
- Koster, D., F. Minette, C. Braun, et O. O’Nagy (2019). Short-term and regionalized photovoltaic power forecasting, enhanced by reference systems, on the example of Luxembourg. *Renewable Energy* 132, 455–470.
- Rasul, K., C. Seward, I. Schuster, et R. Vollgraf (2021). Autoregressive Denoising Diffusion Models for Multivariate Probabilistic Time Series Forecasting. In M. Meila et T. Zhang (Eds.), *ICML*, pp. 8857–8868.
- Redko, I., E. Morvant, A. Habrard, M. Sebban, et Y. Bennani (2019). *Advances in domain adaptation theory*. London : Elsevier.
- Rojat, T., R. Puget, D. Filliat, J. Del Ser, R. Gelin, et N. Diaz-Rodriguez (2021). Explainable Artificial Intelligence (XAI) on Time Series Data : A Survey. arXiv :2104.00950 [cs].
- Salinas, D., M. Bohlke-Schneider, L. Callot, R. Medico, et J. Gasthaus (2019). High-dimensional multivariate forecasting with low-rank Gaussian Copula Processes. *Advances in Neural Information Processing Systems* 32.
- 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.
- Seeger, M. W., D. Salinas, et V. Flunkert (2016). Bayesian Intermittent Demand Forecasting for Large Inventories. In D. D. Lee, M. Sugiyama, U. v. Luxburg, I. Guyon, et R. Garnett (Eds.), *Advances in Neural Information Processing Systems*, Volume 29.
- Taylor, S. J. et B. Letham (2018). Forecasting at Scale. *The American Statistician* 72(1), 37–45.
- Wang, F., Z. Xuan, Z. Zhen, K. Li, T. Wang, et M. Shi (2020). A day-ahead PV power forecasting method based on LSTM-RNN model and time correlation modification under partial daily pattern prediction framework. *Energy Conversion and Management* 212, 112766.
- Wen, R., K. Torkkola, B. Narayanaswamy, et D. Madeka (2018). A Multi-Horizon Quantile Recurrent Forecaster. In O. Anava, A. Khaleghi, V. Kuznetsov, et S. Yang (Eds.), *NIPS Time Series Workshop*.

Summary

Accurate intraday forecasts of PhotoVoltaic (PV) system power outputs are crucial for improving energy distribution grid operations. We present a neural autoregressive model for such forecasts, building upon a physical, deterministic PV performance model. Our approach uses the physical model’s output as covariates and addresses multiple PV sites with a single neural model. We introduce a truncated Gaussian output distribution novel in this context and use a scale-free approach with explicit modeling of seasonal effects. The interest of the approach is validated on real data.