

PRÉDICTION PHOTOVOLTAÏQUE MULTI-HORIZON PAR INTELLIGENCE ARTIFICIELLE

Inasse Lahmar et Pr. Yacine Yaddaden

Département de mathématiques, informatique et génie - Université du Québec à Rimouski
Département Green Tech Institut - Université Mohammed VI Polytechnique



Problématique

- ✓ L'intermittence des énergies renouvelables complique l'équilibre entre l'offre et la demande dans les réseaux électriques. La production solaire photovoltaïque est fortement dépendante des conditions météorologiques, rendant sa prévision difficile [1].



- ✓ Une prédiction précise de la production est essentielle pour assurer la stabilité des réseaux électriques intelligents [2].

Objectifs

- ✓ Simuler une centrale solaire photovoltaïque de 1 MW connectée au réseau afin de générer une base de données de production réaliste.
- ✓ Développer et comparer six modèles d'Intelligence Artificielle (Apprentissage automatique et Apprentissage profond) pour prédire la puissance produite.
- ✓ Explorer le potentiel des données simulées comme alternative aux données de terrain pour l'entraînement des modèles.

Méthodologie

1. Approche méthodologique :

- ✓ Pour prédire la puissance photovoltaïque produite, nous avons suivi un pipeline structuré en cinq étapes, allant de la collecte des données jusqu'à la comparaison des modèles d'intelligence artificielle sur différents horizons temporels.
- ✓ Afin de garantir la représentativité des données, la simulation a été alimentée par des mesures météorologiques réelles de Marrakech, une ville du Maroc qui bénéficie d'un ensoleillement annuel moyen d'environ 3 000 heures et d'une irradiance globale horizontale comprise entre 2 100 et 2 200 kWh/m²/an [3].

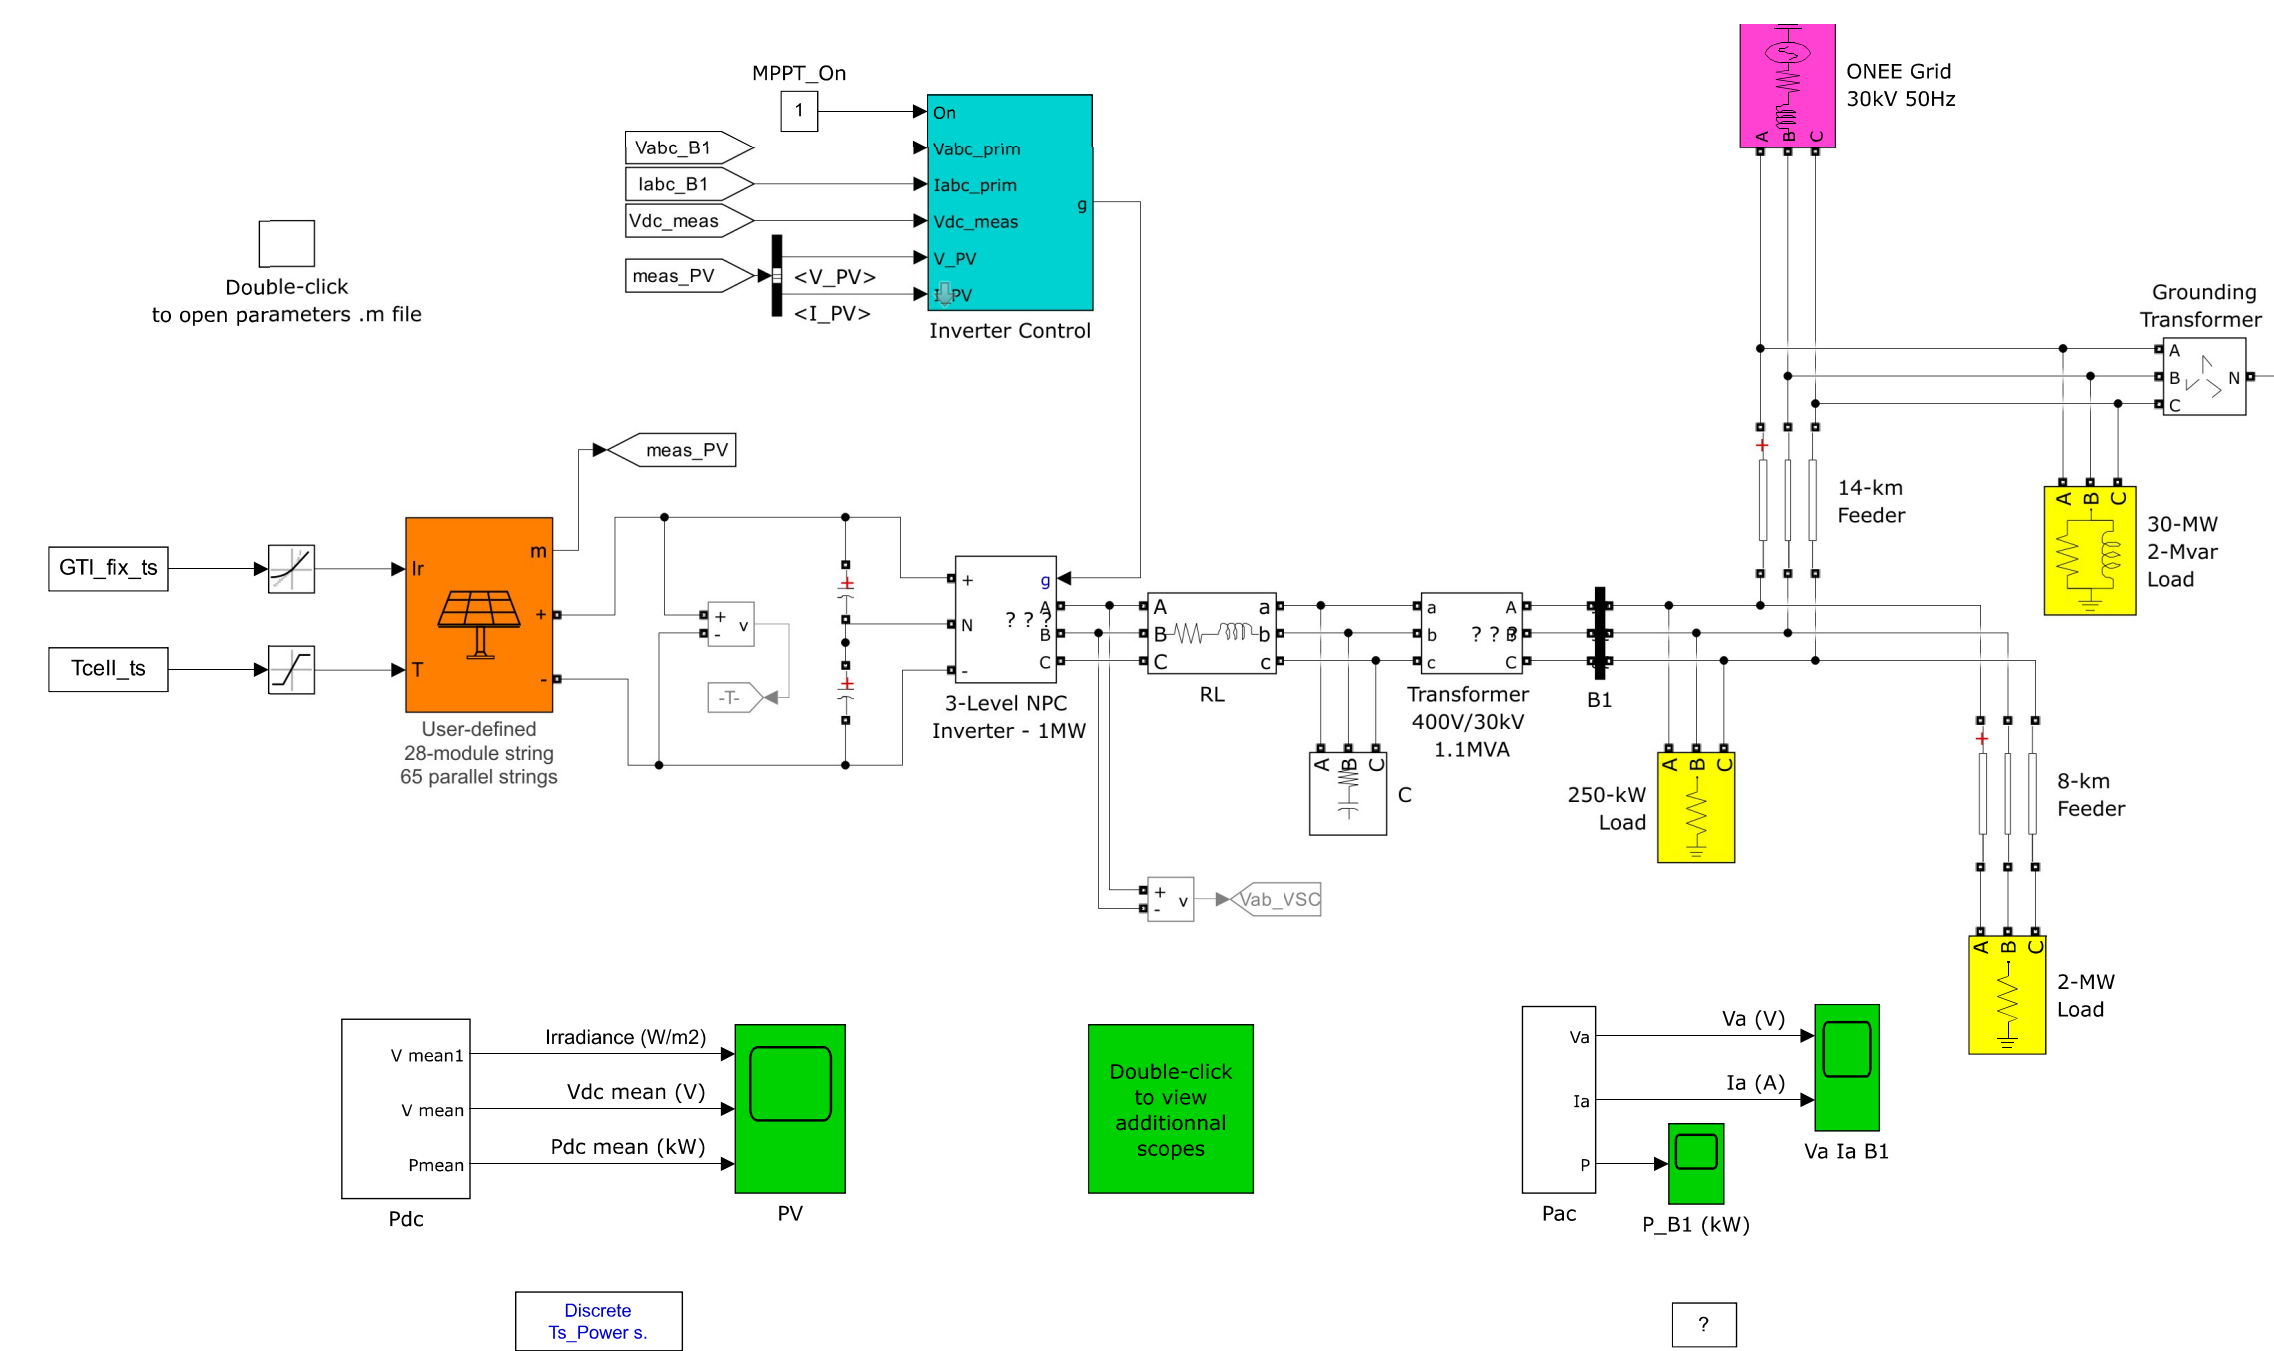
2. Pipeline méthodologique :

1. Récupération des données météo

- ✓ Données météorologiques horaires issues d'OpenMeteo (2010–2026) pour la ville de Marrakech.
- ✓ 14 Variables : GHI, température, humidité, pression, etc.

2. Simulation MATLAB/Simulink

- ✓ les modules utilisés : LONGi LR5-72HPH-550M (550 Wc), 28 en série et 65 strings en parallèle, puissance totale de 1 MW.
- ✓ Le modèle électrique à une diode est calibré aux conditions STC et NOCT avec une erreur inférieure à 5% sur la puissance maximale.
- ✓ L'onduleur NPC 3 niveaux avec le contrôle MPPT assure une injection optimale dans le réseau ONEE 30 kV/50 Hz.
- ✓ Les 14 variables alimentent le modèle pour générer la base de données de production.



3. Base de données de production

- ✓ 65 241 observations horaires de puissance produite.
- ✓ Filtrage aux heures de production (9h–19h).
- ✓ Nettoyage et prétraitement.
- ✓ Séparation chronologique : 80% entraînement, 10% validation, 10% test.

4. Application des modèles d'Apprentissage automatique et Apprentissage profond

- ✓ Random Forest, XGBoost, LightGBM.
- ✓ LSTM, BiLSTM et GRU.

5. Évaluation multi-horizon

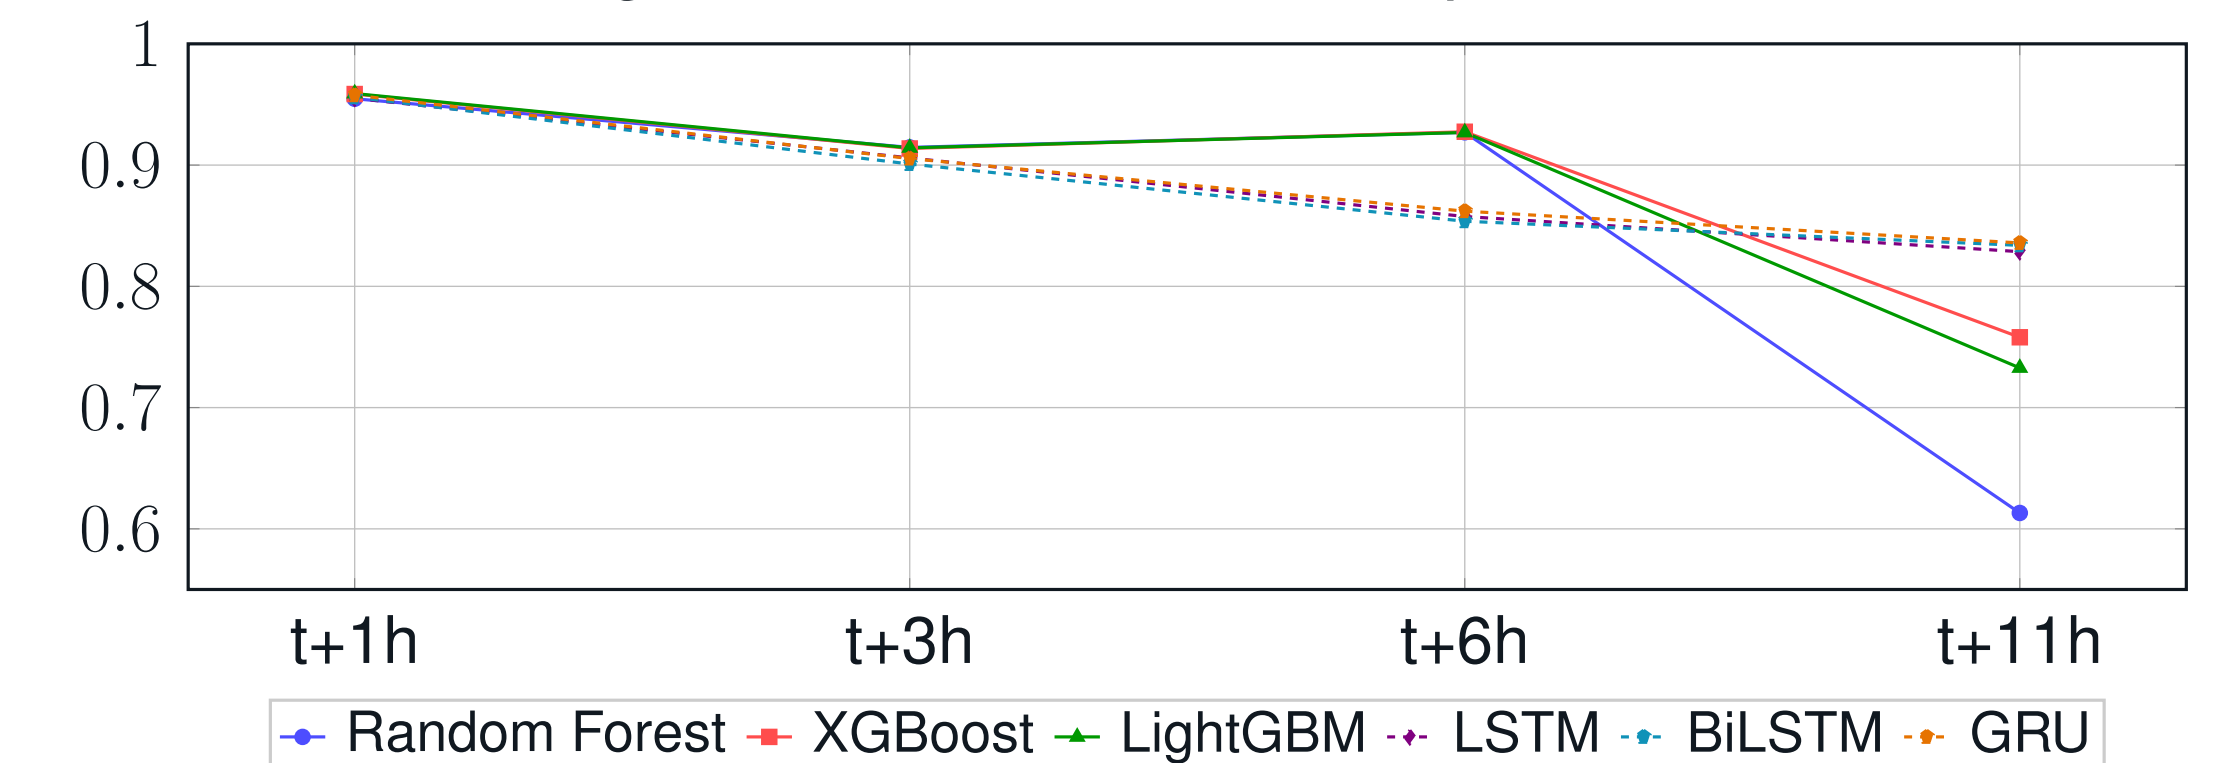
- ✓ Comparaison des modèles sur le jeu de test selon les métriques RMSE et R².
- ✓ Horizons de prédiction évalués : t+1h, t+3h, t+6h et t+11h.

Résultats

Table 1 – Comparaison des modèles testés (RMSE en MW)

Modèle	t+1h		t+3h		t+6h		t+11h	
	RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²
Random Forest	0.0362	0.9547	0.0527	0.9146	0.0411	0.9270	0.0111	0.6131
XGBoost	0.0346	0.9586	0.0530	0.9137	0.0410	0.9275	0.0088	0.7580
LightGBM	0.0344	0.9590	0.0527	0.9142	0.0411	0.9269	0.0092	0.7327
LSTM	0.0365	0.9551	0.0528	0.9059	0.0649	0.8576	0.0712	0.8286
BiLSTM	0.0361	0.9559	0.0542	0.9009	0.0658	0.8537	0.0701	0.8338
GRU	0.0354	0.9576	0.0529	0.9054	0.0639	0.8620	0.0697	0.8358

Figure 1 – Évolution du R² par horizon



Conclusion

Cette étude compare six modèles d'intelligence artificielle pour la prévision de la production photovoltaïque sur plusieurs horizons temporels.

- Les modèles d'Apprentissage automatique surpassent les modèles d'Apprentissage profond sur les horizons courts, avec **LightGBM** comme meilleur modèle global (R²=0.9590). Sur les horizons longs, **GRU** s'impose avec un R²=0.8358, témoignant de la complémentarité et du potentiel de l'intelligence artificielle pour améliorer la planification des réseaux électriques à sources renouvelables intermittentes.

Références

- [1] Mauladdawilah Husein, EJ Gago, Balfaah Hasan, and MC Pegalajar. Towards energy efficiency : A comprehensive review of deep learning-based photovoltaic power forecasting strategies. *Heliyon*, 10(13), 2024.
- [2] Camille Franklin Mbey, Vinny Junior Foba Kakeu, Alexandre Teplaira Boum, and Felix Ghislain Yem Souhe. Solar photovoltaic generation and electrical demand forecasting using multi-objective deep learning model for smart grid systems. *Cogent Engineering*, 11(1) :2340302, 2024.
- [3] R. El Alami et al. Solar energy resource and power generation in morocco : Current situation, potential, and future perspective. *Resources*, 13(10) :140, 2024.