

Prévision de l'irradiance solaire par réseaux de neurones profonds à l'aide de caméras au sol

VINCENT LE GUEN^{1,2}, NICOLAS THOME²

¹ EDF R&D - 6 quai Watier, 78400 Chatou

² CEDRIC, Conservatoire National des Arts et Métiers, 292 rue Saint-Martin, 75003 Paris

vincent.le-guen@edf.fr, nicolas.thome@cnam.fr

Résumé - Nous présentons ici des modèles de réseaux de neurones profonds pour l'estimation de l'irradiance solaire avec des images fisheye. Nous montrons le gain de performances très important par rapport aux méthodes traditionnelles. Pour la prévision, un modèle basé sur des ConvLSTM pour le traitement de séquences d'images est meilleur que les méthodes par flot optique.

Abstract - We present here a deep learning solar irradiance estimation method with fisheye images. We show the huge performance gap with previous methods. For forecasting, a ConvLSTM based algorithm for modeling image sequences shows better performance than optical flow methods.

1 Introduction

L'énergie photovoltaïque (PV) est appelée à prendre une place importante dans notre futur mix énergétique et sa production augmente fortement dans le monde. Toutefois son intégration à grande échelle dans les réseaux électriques existants reste problématique à cause de son intermittence. Les variations brutales de production PV, principalement dues aux passages nuageux, peuvent provoquer des instabilités sur les réseaux. La prévision locale à très court-terme de la production solaire est donc primordiale pour aider le gestionnaire de réseau à assurer l'équilibre à tout instant entre production et consommation d'électricité. La prédiction à court terme (de l'infra-horaire jusqu'à quelques jours) repose principalement sur les images satellitaires et les modèles météorologiques. Toutefois, ces méthodes n'ont pas une résolution temporelle et spatiale suffisante pour modéliser les variations fines dues aux nuages au niveau d'un parc photovoltaïque. Pour cela, sont utilisées de plus en plus fréquemment des caméras au sol avec un objectif « fisheye » qui fournissent une vue hémisphérique du ciel permettant d'anticiper le déplacement des nuages [1].

2 Etat de l'art

La chaîne de traitement traditionnelle des images fisheye consiste en 3 étapes : (1) calibration de la caméra, (2) extraction d'indicateurs discriminatifs et (3) application d'un algorithme d'apprentissage statistique pour la prévision.

La calibration de la caméra sert à déterminer la correspondance entre la position d'un pixel de l'image et ses coordonnées sphériques (azimut, élévation) dans le repère monde. Elle permet de connaître la position théorique du soleil même lorsqu'il est masqué par les nuages. Elle est réalisée par exemple en présentant des damiers connus à la caméra et en suivant la course du soleil sur une journée [2].

Des techniques de segmentation d'images sont ensuite appliquées pour extraire des indicateurs pertinents. Pour

segmenter les nuages, les méthodes classiques se basent sur des seuils sur la différence Rouge-Bleu (R-B) [3], le ratio Rouge-Bleu (R/B) [4], sur des statistiques dans l'espace colorimétrique HSV [5], des caractéristiques de textures [6] ou des combinaisons plus ou moins complexes de ces critères. Le désavantage de ces méthodes est qu'elles nécessitent des paramètres difficiles à ajuster manuellement, et qui diffèrent selon le type ou les réglages de la caméra, et le lieu de la caméra.




Figure 1: station de mesure expérimentale sur l'île de la Réunion

Enfin, pour l'estimation des rayonnements, ces indicateurs sont utilisés en entrée de méthodes d'apprentissage statistique: plus proches voisins [7], perceptrons multi-couches [8], Gradient Boosting [9],... Pour la prévision, ces mêmes méthodes d'apprentissage sont utilisées, ou bien le déplacement perçu des nuages par flot optique est propagé [2, 10].

L'apprentissage profond, qui a connu d'impressionnants succès en vision artificielle ces dernières années, a été appliqué entre autres dans le domaine climatique pour de la classification de nuages sur des images fisheye [11], la prévision de cartes de précipitations [12], ou la prévision de la température de surface des océans [13]. Nous proposons d'utiliser ces méthodes d'apprentissage profond pour l'estimation et la

prévision des rayonnements, afin de valider leur potentiel d'apprentissage de représentations.

3 Données

Une campagne de mesures météorologiques a été menée par EDF R&D depuis 2012 sur l'île de La Réunion. La station (Figure 1) comporte une caméra Fisheye avec un capteur CMOS qui fournit des images RGB de taille 640x480 pixels, un pyranomètre SPN1 (Delta-T-Device) et d'autres instruments de mesure météo. Les images et les rayonnements solaires (Global Horizontal Irradiance (GHI), Diffuse Horizontal Irradiance (DHI), Direct Normal Irradiance (DNI)) sont enregistrés toutes les 10s. Une base de données de plus de 5 millions d'images annotées a été collectée : nous conservons les années 2012 à 2015 comme base d'apprentissage (4190064 images) et l'année 2016 comme base de test (1265717 images). Les images sont traitées à partir d'une élévation solaire de 10°. Les rayonnements sont normalisés par le modèle de ciel clair ESRA (*European Solar Radiation Atlas*) [14] pour éliminer les saisonnalités journalières (nous notons les rayonnements normalisés KGHI, KDHI, KDNI).

4 Modèles proposés

4.1 Estimation du rayonnement

Pour l'estimation de l'irradiance solaire, nous avons entraîné deux modèles de réseaux de neurones convolutifs, qui sont particulièrement adaptés en analyse d'images. Le premier (appelé par la suite *ConvNet*) a une architecture constituée par des blocs de convolutions 2D, activations ReLU et MaxPooling (voir Figure 2). Il prend en entrée des images RGB de taille 100x100 pixels et comporte environ 475000 paramètres.




Figure 2: modèle *ConvNet* pour l'estimation du KGHI

Le deuxième modèle, beaucoup plus profond, est basé sur l'architecture Densenet [15] qui fait partie de l'état de l'art en classification d'images. Les dernières couches de classification sont remplacées par des couches pour la régression des rayonnements. Deux versions ont été entraînées ; *Densenet1* : estimation du KGHI uniquement comme pour *ConvNet*, et *Densenet2* : estimation conjointe du KGHI et du KDHI. Ce modèle prend en entrée des images RGB de taille 224x224 pixels et comporte environ 18 millions de paramètres.

4.2 Prévision du rayonnement

Nous formulons la prévision du rayonnement comme un problème de prévision de séquence temporelle. Etant donnée une série de P images (I_{t-P+1}, \dots, I_t) jusqu'à un instant t , l'objectif est de prédire la séquence des rayonnements futurs (y_{t+1}, \dots, y_{t+F}). Cela revient à maximiser la vraisemblance :

$$\hat{y}_{t+1}, \dots, \hat{y}_{t+F} = \underset{y_{t+1}, \dots, y_{t+F}}{\operatorname{argmax}} p(y_{t+1}, \dots, y_{t+F} | I_t, I_{t-1}, \dots, I_{t-P+1})$$

Nous modélisons cette vraisemblance par une architecture récurrente adaptée aux séquences d'images, comme les ConvLSTM [12] (qui utilisent des convolutions dans les transitions entre états cachés dans le domaine spatial et temporel) et par une perte adaptée à notre prévision. Trois couches de ConvLSTM sont empilées avec 64 neurones chacune. Le dernier état caché résume l'information apprise de la séquence d'images sur le déplacement des nuages. Des couches de convolutions sont utilisées pour prédire conjointement l'image future à $t+F$ et le rayonnement futur KGHI à $t+F$ (la Figure 3).

Un modèle ConvLSTM sans la prédiction de l'image future a été testé, mais les résultats étaient moins bons. Nous supposons que la supervision additionnelle apportée par l'image future aide le modèle dans son apprentissage en le forçant à imaginer la position future des nuages.

Dans nos expériences, nous utilisons une séquence d'entrée de $P=11$ images espacées de 30s, et nous faisons une prédiction à 5min ($F=10$). Pour des raisons de temps de calcul pour l'apprentissage de ce premier modèle, nous convertissons les images d'entrée en niveaux de gris et les réduisons à une taille de 60x60 pixels.




Figure 3: architecture du réseau de neurones ConvLSTM pour la prédiction du rayonnement

Précisons que la calibration de la caméra n'est pas nécessaire pour les modèles d'estimation et de prévision.

4.3 Implémentation

Les différents modèles ont été développés en Python avec les bibliothèques Keras/Tensorflow et entraînés sur un GPU Nvidia Quadro P6000.

Pour le modèle d'estimation Densenet, nous n'avons pas remarqué de différence entre une initialisation des poids des couches convolutionnelles par ceux appris sur




Figure 4: Résultats d'estimation du GHI et du DHI sur des images particulières du jeu de test.

ImageNet, par rapport à une initialisation aléatoire (à part une décroissance de la perte plus rapide au début). Notre base de données est donc suffisamment riche pour un apprentissage intégral des réseaux.

5 Résultats expérimentaux

5.1 Estimation du rayonnement

Notre méthode de base est celle développée à EDF R&D [2] qui segmente les images par des seuils sur la différence R-B et la luminance pour définir 5 indicateurs, et applique une régression à noyau (Nadaraya & Watson [16]). Sur ces mêmes 5 indicateurs, nous comparons également une régression linéaire (RegLin) et un algorithme de gradient boosting (Xgboost), dont les paramètres sont optimisés par validation croisée.

La métrique utilisée est la *Root Mean Squared Error* (RMSE), et sa valeur normalisée (nRMSE) par la valeur moyenne du KGHI sur la base d'apprentissage (vaut 0.6796). Le Tableau 1 présente les résultats d'estimation du rayonnement normalisé KGHI.

Tableau 1: résultats d'estimation de l'irradiance KGHI sur la base de test (année 2016 La Réunion, 1265717 images)

	RMSE	nRMSE
Méthode de base	0.146	21.6 %
RegLin	0.193	28.4 %
XGBoost	0.142	20.8 %
ConvNet	0.0699	10.3 %
DenseNet1	0.0352	5.27 %
DenseNet2	0.0328	4.83 %

Nous constatons que l'apprentissage profond permet un grand saut de performance avec les méthodes d'apprentissage basées sur les indicateurs extraits manuellement (ConvNet fait décroître le nRSME de 20.8% à 10.3% par rapport à XGBoost). Cela confirme que les réseaux de neurones sont capables de créer une représentation interne des images particulièrement adaptée à cette tâche de régression. L'autre gain très important vient du passage à un réseau convolutionnel très profond (de 10.3% à 5.27% de nRMSE pour le DenseNet1). Le modèle DenseNet2 a un très léger avantage sur le DenseNet1 (4.83 %), suggérant que la

supervision supplémentaire par le rayonnement diffus est bénéfique pour avoir une meilleure estimation du rayonnement global.

Sur des exemples d'estimation sur des images particulières (Figure 3), quelle que soit la couverture nuageuse, on constate que l'estimation Densenet du GHI et du DHI est systématiquement plus proche de la mesure que la méthode de base. De plus, cet avantage est d'autant plus marqué lorsque le rayonnement diffus est important (exemples (d) et (e)), car le DHI est difficile à estimer avec les indicateurs de segmentation définis manuellement (il dépend des nuances de gris des nuages).

5.2 Préviation du rayonnement

Un modèle de base pour les problèmes de prévision est la persistance, qui consiste à fournir la valeur courante du rayonnement normalisé comme prédiction future. Ce modèle est parfait pour une journée de ciel clair, mais est toujours en retard de l'horizon de prédiction en cas de variation. La comparaison à la persistance (vrai rayonnement à l'instant t ou estimé par ConvNet) permet de mettre en évidence le pouvoir d'anticipation d'un modèle prédictif.

La méthode de base d'EDF R&D [2] utilise le flot optique calculé entre 2 images et propage le déplacement moyen des nuages pour construire une image future dont l'irradiation est estimée.

Deux méthodes avec des réseaux convolutionnels ont été entraînées pour prédire directement le rayonnement futur : la première prend en entrée l'image courante I_t (*ConvNet-B1*), la deuxième la concaténation de I_{t-1} et I_t (*ConvNet-B2*). Nous présentons des résultats de prévisions à 5min pour 4 journées (7, 8, 9 et 10 avril 2016).

Tableau 2: résultats globaux de prévisions à 5min pour 4 journées d'avril 2016

	RMSE	nRMSE
Méthode de base	0.229	32.9 %
Persistance	0.198	28.5 %
Persistance-ConvNet	0.195	28.8 %
ConvNet-B1	0.190	28.0 %
ConvNet-B2	0.190	28.0 %
Conv1stm	0.168	24.8 %

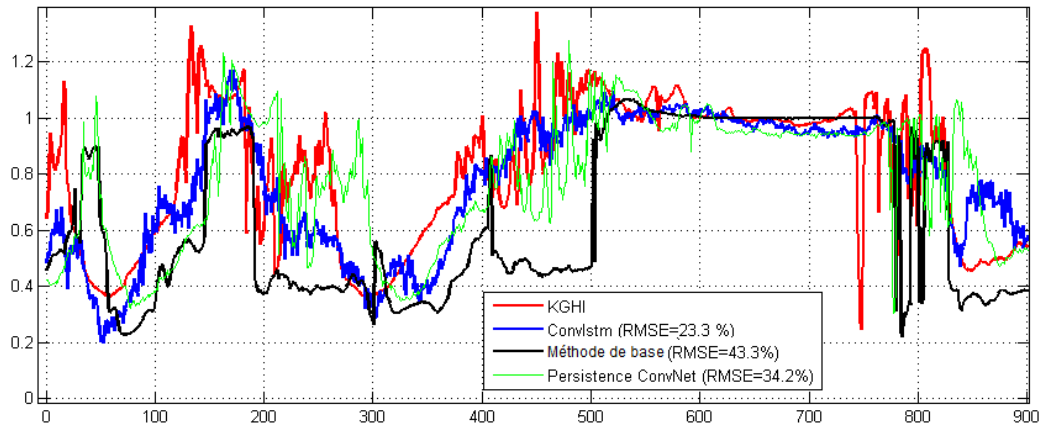


Figure 5: prédictions du KGHI à 5min sur une journée particulière

Nous voyons que les 2 modèles ConvNet-B1 et B2 sont approximativement équivalents et légèrement plus performants que la méthode de base et que la persistance. Le modèle ConvLstm qui traite en entrée un plus long historique de 10 images passées obtient le meilleur score de prévision (24.8%).

Toutefois, il faut rester prudent avec les métriques globales comme la RMSE car elles reflètent mal la capacité d'anticiper des variations brutales [17]. Sur la Figure 5, le modèle de persistance ConvNet (courbe verte) a une meilleure RMSE (34.2%) que la méthode de base (en noir 43.3%). Pourtant, cette méthode de base anticipe bien mieux les chutes (par exemple au pas de temps 200, ce qui est plus intéressant pour notre application) mais est pénalisée par certaines fortes erreurs en valeur absolue.

6 Conclusion

Nous avons proposé une méthode d'apprentissage profond par réseaux de neurones convolutifs pour l'estimation du rayonnement solaire à partir d'images fisheye, qui ne nécessite ni calibration de la caméra ni extraction d'indicateurs experts, et obtient des performances bien supérieures aux méthodes traditionnelles. Nos premiers réseaux récurrents pour la prévision spatio-temporelle sont également très prometteurs et devront être approfondis, ainsi que les métriques pour les entraîner et évaluer.

Remerciements

Nous souhaitons remercier EDF R&D, les départements PRISME et MFEE et en particulier Bruno Charbonnier, Christophe Chaussin, Dominique Demengel et Stéphanie Dubost pour la qualité de l'instrumentation, de la chaîne d'acquisition et de traitement des données.

Références

- [1] Marquez, R., Coimbra, 2013. Intra-hour dni forecasting based on cloud tracking image analysis. *Solar Energy* 91, 327-336.
- [2] Gauchet, C., Blanc, P., Espinar, B., Charbonnier, B., Demengel, D., 2012. Surface solar irradiance estimation with low-cost fisheye camera, in: *Workshop on "Remote Sensing Measurements for Renewable Energy"*.
- [3] Heinle, A., Macke, A., Srivastav, A., 2010. Automatic cloud classification of whole sky images. *Atmospheric Measurement Techniques* 3, 557-567.
- [4] Yang, H., Kurtz, B., Nguyen, D., Urquhart, B., Chow, C.W., Ghonima, M., Kleissl, J., 2014. Solar irradiance forecasting using a ground-based sky imager developed at UC San Diego. *Solar Energy* 103, 502-524.
- [5] Chu, Y., Li, M., Coimbra, C.F., 2016. Sun-tracking imaging system for intra-hour dni forecasts. *Renewable Energy* 96, 792-799.
- [6] Schmidt, T., Kalisch, J., Lorenz, E., Heinemann, D., 2016. Evaluating the spatio-temporal performance of sky-imager-based solar irradiance analysis and forecasts. *Atmospheric chemistry and physics* 16, 3399-3412.
- [7] Pedro, H.T., Coimbra, C.F., 2015. Nearest-neighbor methodology for prediction of intra-hour global horizontal and direct normal irradiances. *Renewable Energy* 80, 770-782.
- [8] Chu, Y., Pedro, H.T., Li, M., Coimbra, C.F., 2015. Real-time forecasting of solar irradiance ramps with smart image processing. *Solar Energy* 114, 91-104.
- [9] Pedro, H.T., Coimbra, C.F., David, M., Lauret, P., 2018. Assessment of machine learning techniques for deterministic and probabilistic intra-hour solar forecasts. *Renewable Energy* 123, 191-203.
- [10] Bernecker, D., Riess, C., Angelopoulou, E., Hornegger, J., 2014. Continuous short-term irradiance forecasts using sky images. *Solar Energy* 110, 303-315.
- [11] Liu, S., Li, M., Zhang, Z., Xiao, B., Cao, X., 2018. Multimodal ground-based cloud classification using joint fusion convolutional neural network. *Remote Sensing* 10, 822.
- [12] Xingjian, S. H. I., Chen, Z., Wang, H., Yeung, D. Y., Wong, W. K., & Woo, W. C. (2015). Convolutional LSTM network: A machine learning approach for precipitation nowcasting. In *NIPS 2015* (pp. 802-810).
- [13] De Bezenac, E., Pajot, A., & Gallinari, P. (2018). Deep learning for physical processes: Incorporating prior scientific knowledge. *ICLR 2018*.
- [14] Rigollier, C., Bauer, O., Wald, L., 2000. On the clear sky model of the esra european solar radiation atlas with respect to the heliosat method. *Solar energy* 68, 33-48.
- [15] Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K.Q., 2017. Densely connected convolutional networks, in: *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 4700-4708.
- [16] Nadaraya, E.A., 1964. On estimating regression. *Theory of Probability & Its Applications* 9, 141-142.
- [17] Vallance, L., Charbonnier, B., Paul, N., Dubost, S., & Blanc, P. (2017). Towards a standardized procedure to assess solar forecast accuracy: A new ramp and time alignment metric. *Solar Energy*, 150, 408-422.