Application d'algorithmes de Machine Learning pour la détection et identification des défauts du côté DC des installations photovoltaïques résidentielles

M'ZOUGH Walid [(1)(2)], SIDQI Yousra [(1)], DELINCHANT Benoit [(2)]

(1) Haute Ecole de Lucerne, Ingénierie et Architecture, Horw 6048, Suisse ;
(2) Univ. Grenoble Alpes, CNRS, Grenoble INP, G2Elab, 38000 Grenoble, France.

CONTEXTE

Les modules photovoltaïques (PV) sont vulnérables aux défaillances qui réduisent considérablement leur efficacité, mais les inspections manuelles sont peu pratiques. Pour y remédier, on a recours à l'analyse des mesures électriques tels que les signaux de courant/tension, courbes I-V, spectre de Tension/Courant etc. [1]. Cependant, les classificateurs de défauts PV qu'on trouve dans la littérature sont souvent basés sur des données simulées ou ne prennent pas en compte une large gamme de défauts possibles [2]. On cherche donc à pouvoir détecter et identifier avec haute précision la nature d'une anomalie PV sans devoir utiliser des solutions/techniques couteuses qui limitent l'usage dans le cadre résidentiel [3], tout en exploitant l'apport IA/ML dans ce domaine.

TRAVAUX EN COURS ET RESULTATS

Afin de répondre à la problématique, nous exploitons les micro-onduleurs solaires largement présents dans les installations résidentielles et qui intègrent l'accès aux mesures électriques au niveau du module. La solution va consister en un modèle classificateur qui reçoit les données du côté DC de l'installation, détermine la présence d'un défaut et sa nature, puis notifie l'utilisateur. Dans ce qui suit, nous explorons les performances de quelques modèles classificateurs de défauts.

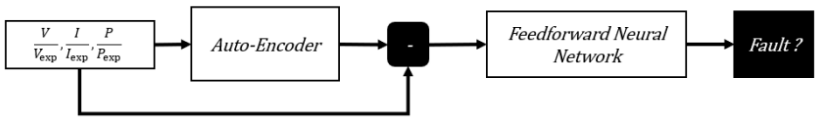

Figure. Schéma du détecteur de defauts à base d'un Auto-Encodeur

Le jeu de données utilisé contient plus de 370,000 entrées mesurées à un pas d'une minute sur un système réel basé à Horw, Lucerne en Suisse. Les mesures instantanées effectuées sont ceux de la tension, courant, puissance tous du côté DC, la température du module et l'irradiation GHI. Sur cette base on applique des scenarios émulant huit défauts. La tension mesurée V, le courant mesuré I et la puissance mesurée P sont normalisées par les valeurs V_{exp}, I_{exp} et P_{exp} générées par un modèle mathématique du système.

Une **classification en deux temps** (Détection puis Identification si défaut présent) a été appliquée. La classe « absence défauts » est parfaitement détectée par un **réseau neuronal a propagation directe** (FFNN) qui d'ailleurs confond plus de 50% des échantillons de la classe « présence défaut ». On retient les valeurs importantes de la matrice de confusion du FFNN utilisé en étape d'identification : tous les défauts sont identifiés avec un taux de rappel de 90% ou plus sauf pour les défauts « Salissure sur les bords » (62.2 %) et « Bris de verre » (81.6 %).

Par la suite, nous nous intéressons à la détection en explorant d'autre modèles qui exploitent les dépendances temporelles entre les données : **réseaux neuronaux convolutionels** (CNN) et **auto-encodeurs** (AE). Pour le CNN, on constate une amélioration légère en détection (<3%). D'autre part, le signal régénéré par l'AE (entrainé que sur les signaux seins) est soustrait du signal original pour obtenir une erreur de reconstruction qu'on met entrée d'un autre FFNN qui en décide comme montre la figure ci-haut. La performance en détection de cette approche augmente le taux de rappel de la classe « présence défauts » a 78.8% pourtant le même taux pour la classe « absence défauts » descend à 80%.

Pour synthétiser, la première approche nous a permis de se focaliser sur la détection. L'application d'un CNN pour exploiter les dépendances temporelles a permis de légèrement améliorer la détection. L'AE améliore la détection d'un défaut de 18.5% mais au prix d'une baisse du taux de rappel de la classe « absence défauts ».

REFERENCES

[1] R. A. Ying-Yi Hong, "Methods of photovoltaic fault detection and classification: A review," Energy Reports, vol. Volume 8, pp. Pages 5898-5929, 2022.

[2] G. Tina, C. Ventura, S. Ferlito and S. De Vito, "A State-of-Art-Review on Machine-Learning Based Methods for PV," Appl. Sci., pp. 11, 7550, 2021.

[3] N. B. P. S. D. I. B. K. Menghong Feng, "SunDown: Model-driven Per-Panel Solar Anomaly Detection for Residential Arrays," arXiv, 2020.