



**HAL**  
open science

# L'intelligence artificielle pour la gestion des réseaux de distribution

Aleksandr Petrusev, Vincent Debusschere, Rémy Rigo-Mariani, Patrick Reignier, Nouredine Hadjsaid

► **To cite this version:**

Aleksandr Petrusev, Vincent Debusschere, Rémy Rigo-Mariani, Patrick Reignier, Nouredine Hadjsaid. L'intelligence artificielle pour la gestion des réseaux de distribution. La Revue de l'électricité et de l'électronique, 2022. hal-03720550

**HAL Id: hal-03720550**

**<https://hal.science/hal-03720550v1>**

Submitted on 12 Jul 2022

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# L'intelligence artificielle pour la gestion des réseaux de distribution

**Aleksandr Petrushev**, Doctorant, INP Grenoble

**Vincent Debusschere**, Maître de Conférence, INP Grenoble

**Rémy Rigo-Mariani**, Chargé de Recherche, CNRS

**Patrick Reignier**, Professeur des Universités, INP Grenoble

**Nouredine Hadjsaid**, Professeur des Universités, INP Grenoble

## Introduction

Les réseaux de distribution sont des systèmes complexes qui nécessitent supervision et contrôle. De façon non exhaustive, cela inclut les tâches suivantes :

- Contrôler les échanges de puissance avec le réseau de transport au niveau des postes sources. Cela dépend du contrôle des flexibilités et de la charge (délestage) ;
- Maintenir la tension dans les bornes contractuelles par le contrôle des moyens d'action sur la tension (condensateurs, régulateurs de tension, flexibilités, reconfigurations, etc.) ;
- Isoler automatiquement une zone en défaut ;
- Détecter puis localiser les défauts du réseau, en lien avec les systèmes de protection ;
- Restaurer/reconfigurer le système en fonction de recommandations et de simulations de scénarios ou d'expertise métier. Définir la séquence d'opérations de reconfiguration optimale permettant de réalimenter au mieux les zones isolées ;
- Gérer les congestions par le réacheminement automatique de production vers les charges ;
- Réduire les pertes sous contraintes opérationnelles, c'est-à-dire tout en maintenant une configuration fiable du système ;
- Planifier la maintenance des équipements, mettre hors service un dispositif avec une séquence de déconnexion certifiée.

Les systèmes experts traditionnellement utilisés pour traiter la plupart de ces tâches présentent des limitations, telles que :

- Le manque de réponses créatives dont les experts humains sont capables ;
- La difficulté à automatiser des processus complexes ;
- L'insuffisance de la flexibilité et de la capacité d'adaptation aux environnements changeants ou incertains ;

De plus, l'écosystème électrique se modifie profondément. Tout d'abord, une injection croissante d'énergie renouvelable (ENR) sur le réseau moyenne tension (HTA) comme basse tension (BT) amène l'opérateur de réseau de distribution à adopter un rôle plus actif dans ses échanges avec l'opérateur de réseau de transport, au lieu d'être un simple gestionnaire d'incidents.

Ensuite, la pose des compteurs communicants ainsi que les capacités de mesure sur l'ensemble du réseau apportent un volume et une variété d'information significatifs sur le réseau BT. Le besoin de coordonner la conduite du réseau HTA avec une supervision des réseaux BT se développe d'autant plus que cette donnée pourra être utilisée efficacement, notamment du fait de la généralisation de nouveaux mécanismes pour optimiser la gestion du réseau.

Les technologies basées sur l'intelligence artificielle (IA), dont beaucoup ont été développées au 20ème siècle, ont commencé à montrer leur efficacité ces dernières années grâce à l'augmentation de la puissance de calcul et du volume de données. Cela conduit à un intérêt accru pour l'utilisation de l'IA,

ou plus particulièrement de l'apprentissage automatique, pour accompagner les tâches opérationnelles et de planification des gestionnaires de réseau.

C'est l'objet de cet article, qui fait un tour (non exhaustif) des principales techniques d'IA dont les capacités présentent un intérêt avéré ou prévisionnel pour la gestion des réseaux électriques de distribution. Cet article est organisé comme suit : On y décrit d'abord les grandes catégories d'algorithmes d'IA couramment utilisés sur ce sujet dans la littérature. Le chapitre suivant traite plus spécifiquement de l'IA pour les applications de contrôle par rapport aux approches classiques. enfin le dernier chapitre s'intéresse aux algorithmes d'IA pour des usages de conseil, de diagnostic ou d'interprétation d'état du système électrique.

## Les techniques d'intelligence artificielle

### Machine Learning

L'apprentissage automatique (ou *Machine Learning*, ML) est un domaine d'étude de l'intelligence artificielle sur des algorithmes qui « apprennent » à partir de données, en améliorant leurs performances à résoudre des tâches sans être explicitement programmés pour chacune d'elles.

Les algorithmes peuvent être catégorisés selon le mode d'apprentissage qu'ils emploient (Figure 1).

- **Apprentissage supervisé** : Si les classes (e.g. décisions optimales) sont prédéterminées et les résultats sont connus, le système apprend selon un modèle de classification. Les techniques typiques sont *Support Vector Machines* (SVM), *artificiel neural network* (ANN) ou *Deep Learning* (DL).
- **Apprentissage non supervisé** : l'algorithme doit découvrir par lui-même la structure plus ou moins cachée des données. L'intérêt est de trouver des corrélations entre les données très variées que l'humain (même expert) ne verrait pas. Les exemples typiques sont *K-means* et *Anomaly detection*.
- **Apprentissage par renforcement (ou reinforcement learning, RL)** : l'algorithme apprend de sa propre expérience. L'action de l'algorithme sur l'environnement produit une valeur de retour qui guide son apprentissage. Les exemples typiques sont *Q-Learning* et *PPO*.



Figure 1. Catégories d'apprentissage automatique (tiré de **Erreur ! Source du renvoi introuvable.**).

### **Apprentissage profond (Deep learning)**

Les techniques d'apprentissage profond (ou *deep learning*, DL) constituent une classe d'algorithmes d'apprentissage automatique qui utilisent différentes couches d'unité de traitement non linéaires pour l'extraction des caractéristiques intrinsèques à un jeu de données. Chaque couche prend en entrée la sortie de la couche précédente avec un ensemble de poids, dont la difficulté est la sélection des valeurs. A travers les différentes couches, on passe de paramètres de bas niveau à des paramètres de plus haut niveau, en montant en abstraction concernant les données, ce qui donne un fonctionnement interne souvent incompréhensible pour l'opérateur humain de l'algorithme.

### **Les machines à vecteurs de support (Support Vector Machines)**

Les SVM sont des classifieurs qui reposent sur deux idées principales. La première est la notion de marge, qui est la distance entre une frontière et des échantillons. Elle est mesurée via les vecteurs supports. Le choix de la frontière de séparation doit maximiser cette marge. L'idée est de trouver la frontière séparatrice optimale sur un ensemble d'apprentissage.

Afin de pouvoir traiter des cas où les données ne sont pas linéairement séparables, la deuxième idée clé des SVM est de transformer l'espace de représentation des données d'entrées en un espace de plus grande dimension, dans lequel il est probable qu'il existe une séparation linéaire. Cette technique est connue sous le nom de *kernel trick*.

### **Apprentissage par renforcement (Reinforcement learning)**

Les principaux éléments de RL sont **Erreur ! Source du renvoi introuvable.**:

- L'environnement : le système considéré est représenté à l'instant  $t$  par des variables d'état  $s_t$  suite à un ensemble d'actions  $a_t$  (e.g. suite de contrôles dans le temps) ;
- L'agent : le contrôleur qui génère l'action  $a_t$ , en fonction de l'état du système  $s_t$ , et amenant l'état suivant  $s_{t+1}$  une fois que les actions sont effectuées dans l'environnement ;
- La récompense  $r_t$  : la métrique de l'objectif du contrôleur, calculée à partir de l'état  $s_{t+1}$ , pour évaluer la pertinence des actions entreprises.

Le but final de l'algorithme RL est de trouver une politique optimale  $\pi$  qui est une cartographie des liens entre états et actions,  $a_t = f(s_t)$ . La politique est générée de manière à maximiser une récompense cumulée sur une horizon de temps  $T$  qui dépend de cette cartographie.

## **L'intelligence artificielle pour contrôler la tension et la puissance**

### **Motivations**

Les applications traditionnelles de contrôle dans le cadre des réseaux électriques, et en particulier les réseaux de distribution, reposent sur la mise en œuvre d'une stratégie de « commande prédictive » (*model predictive control*). Dans ce type d'architecture, les décisions sont prises sur la base d'une modélisation des systèmes et en fonction de prédictions sur leur état (par exemple prédiction de consommation/production). Le calcul des contrôles peut se faire à partir de règles métiers et/ou de la résolution d'un problème d'optimisation (Figure 2). Les objectifs peuvent être techniques (e.g. pertes), économiques (e.g. facture énergétique), et/ou environnementaux (e.g. émissions) et les contrôles doivent tenir compte de contraintes opérationnelles telles que les limites en tension et courant. De telles stratégies de contrôles sont sujettes à trois principales sources d'incertitudes :

- Les incertitudes de prédiction classique sur les séries temporelles de production/consommation ( $\tilde{w}_t$ ).
- Le manque de fidélité des modèles analytiques – approximations des fonctions  $f$  et  $g$ .
- Des inconnues sur les paramètres des modèles  $Z$  – e.g., incertitudes sur les impédances de ligne.

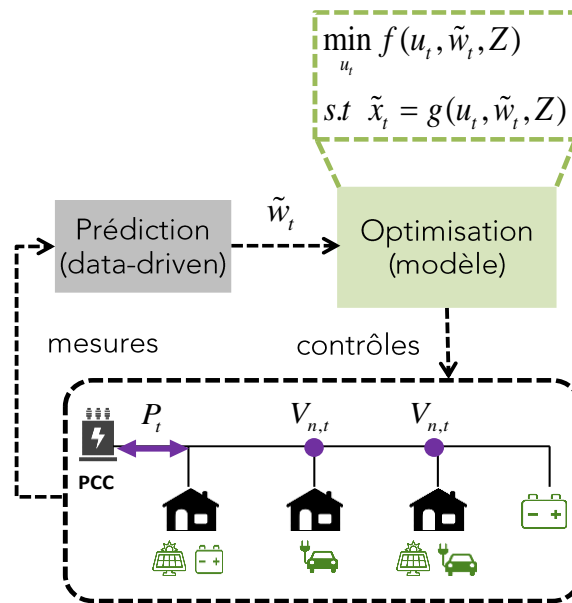


Figure 2. Approches traditionnelles de commande prédictive.

Une autre limitation des approches à base d'optimisation est qu'elles peuvent dans certains cas nécessiter de long temps de calcul avant convergence. Certaines solutions prennent également la forme d'applications hébergées dans le « cloud » (e.g., stratégie de management de l'énergie) et peuvent donc être sujettes à des pertes de connexion/communication. L'idée est donc de tirer profit de l'IA par l'apprentissage à base d'expérience pour augmenter la robustesse et la rapidité des contrôles pour des applications critiques, au plus proches des équipements (*edge*).

### Réglage de la tension/puissance

Pour le contrôle de tension et de puissance, il existe une grande variété d'algorithmes. Les méthodes les plus populaires actuellement tournent autour du DL (*deep learning*) **Erreur ! Source du renvoi introuvable.** Il est également possible d'utiliser une approche de type *radial basis function* (RBF) *networks* **Erreur ! Source du renvoi introuvable.** Enfin, les SVM dans lesquels les valeurs de paramètres optimales sont obtenues à l'aide d'un algorithme génétique sont parfois proposés pour la surveillance de la tension en ligne **Erreur ! Source du renvoi introuvable.**

La mise en œuvre du RL ou plus précisément du *Q-learning* est aussi largement mentionnée dans la littérature pour le contrôle de la tension et de la puissance **Erreur ! Source du renvoi introuvable.** Il est ainsi possible de refléter à la fois la perte de réseau et le coût de commutation avec un terme de violation de contrainte dans la récompense de *reinforcement learning* **Erreur ! Source du renvoi introuvable.** L'utilisation d'un algorithme d'optimisation de type *artificial immune system* pour l'entraînement d'un outil RL avec un système multi-agents permet d'accélérer l'obtention de résultats par rapport aux outils d'optimisation standards **Erreur ! Source du renvoi introuvable.** Enfin, l'algorithme *Safe off-policy*, basé sur du DRL (*deep reinforcement learning*) et des réseaux de neurones peut être pertinent pour résoudre les problèmes de contrôle tension/puissance réactive **Erreur ! Source du renvoi introuvable.**

### Stratégies d'Implémentation

L'implémentation de méthodes à base d'IA pour les applications de contrôles a donc pour but de remplacer l'ensemble de la chaîne de commande prédictive par des contrôleurs locaux et rapides. Typiquement les contrôleurs sont entraînés hors lignes avant un déploiement en ligne. En cas d'apprentissage supervisé, l'entraînement revient à cartographier des mesures d'entrées (historiques) avec des contrôles optimaux issues d'une optimisation sur base de modèles (Figure 3a). En cas d'apprentissage par renforcement, une première politique optimale peut-être définie dans une étape

hors ligne en simulant le système. Le contrôleur peut par la suite réaliser un ajustement en ligne à partir des « vraies » mesures pour tenir compte d'éventuelles déviations par rapport au modèle de départ (Figure 3b).

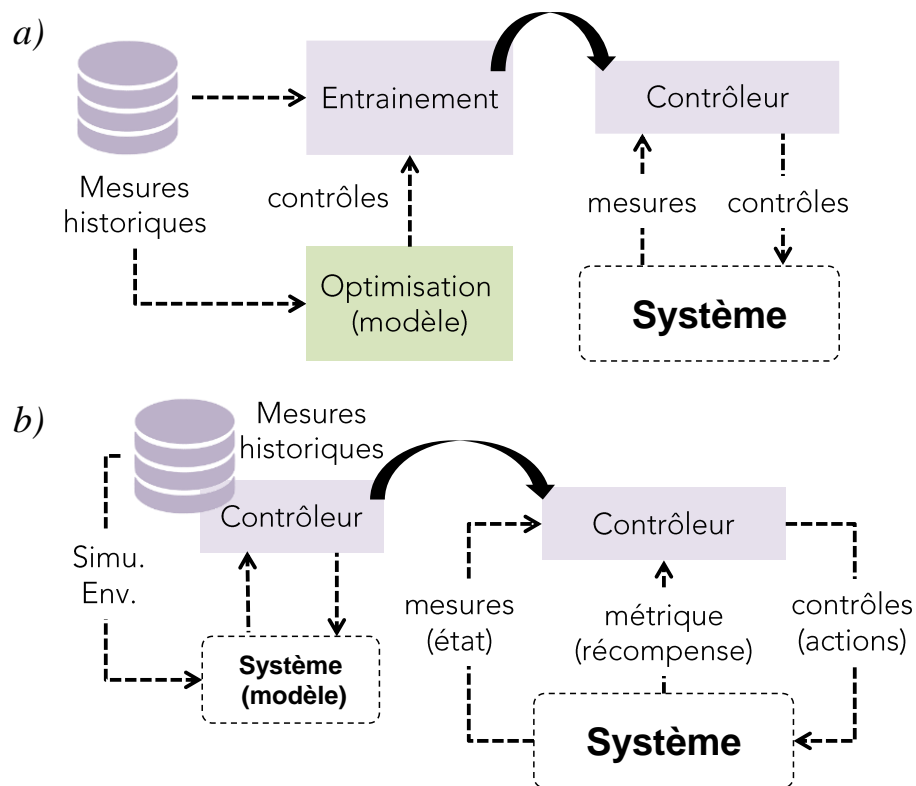


Figure 3. Stratégies d'implémentation avec entraînement hors-ligne

a) supervisé, b) renforcement.

## L'intelligence artificielle pour les systèmes de conseil /diagnostic / interprétation

### Prévision de la courbe de charge

Une autre application populaire basée sur l'IA réside est la prévision de la courbe de charge à plusieurs échelles géographiques et temporelles. Par exemple, un *multilayer perceptron* (MLP) standard, seul **Erreur ! Source du renvoi introuvable.** ou avec des *stacked autoencoders* (un type spécifique de réseau de neurones) **Erreur ! Source du renvoi introuvable.**, montrent une bonne stabilité et une précision acceptable. Une solution plus efficace et plus rapide est parfois d'avoir recours à un *convolutional neural network* (CNN) seul **Erreur ! Source du renvoi introuvable.** ou conjointement avec un algorithme *K-Means* **Erreur ! Source du renvoi introuvable.** pour mieux prendre en compte la relation avec le temps.




Figure 4. Principe du *Recurrent neural networks* Erreur ! Source du renvoi introuvable.

Les *recurrent neural networks* (RNN) (Figure 4) et, dans une certaine mesure, le *long short-term memory* (LSTM) présentent un comportement temporel dynamique, mais ils nécessitent plus de temps pour le calcul Erreur ! Source du renvoi introuvable.. Une technique de modélisation hybride basée sur la combinaison de DL avec un CNN (réseau de neurones convolutif, *convolutional neural network*) et une combinaison avec une SVM (Machine à vecteurs de support, *Support Vector Machines*) est enfin possible Erreur ! Source du renvoi introuvable..

Les *deep belief networks* (DBN) sont une autre solution très populaire pour faire des prévisions de charge électrique à court terme Erreur ! Source du renvoi introuvable.. Les DBN peuvent également être intégrés avec des modèles de copules paramétriques (fonctions de distribution cumulatives) Erreur ! Source du renvoi introuvable.. Un autre exemple prometteur est la combinaison de DBN et *support vector regression* Erreur ! Source du renvoi introuvable.. Enfin, une autre méthodologie utilise les *RBF neural networks* Erreur ! Source du renvoi introuvable..

### Détection

La littérature scientifique fait état d'une grande variété d'algorithmes pour les tâches de détection des défauts. Par exemple, le *self-encoding neural network* peut être utilisé, dans lequel l'énergie est normalisée en termes de sous-bandes de *wavelet decomposition* est utilisée comme paramètre caractéristique du réseau neuronal DL Erreur ! Source du renvoi introuvable.. Une autre possibilité est de décomposer la tension transitoire par *wavelet filter* pour la formation de l'ANN Erreur ! Source du renvoi introuvable.. Une méthode plus simple consiste à utiliser un ANN se basant sur les résultats d'une transformation de Fourier rapide Erreur ! Source du renvoi introuvable.. Un autre exemple d'utilisation de DL avec un encodeur automatique est donné dans Erreur ! Source du renvoi introuvable.. Un algorithme de détection de *graph convolutional network* (GCN) (Figure 5) avec *principal component analysis* (PCA) est présenté dans Erreur ! Source du renvoi introuvable..




Figure 5. Structure du modèle GCN.

(Plusieurs couches de convolution de graphe sont suivies de deux couches entièrement connectées)  
(figure reprise de [14]).

Une méthode efficace pour la classification SVM utilise par exemple le statut des compteurs intelligents des clients **Erreur ! Source du renvoi introuvable.** En cas de séquences critiques de cyberattaques, une approche basée sur le *Q-learning* peut enfin être utilisée **Erreur ! Source du renvoi introuvable.**

### **Classification**

Pour la tâche de classification automatique des perturbations, (comme un déclenchement de producteur, un délestage, un déclenchement de ligne) les MLP, DBN et CNN sont des choix possibles, mais en comparant des algorithmes seuls, CNN semble surpasser les autres en termes de précision **Erreur ! Source du renvoi introuvable.** Une autre option consiste à utiliser des SVM formés individuellement en tant que nœuds dans un *binary decision tree* **Erreur ! Source du renvoi introuvable.** Une approche plus complexe est le couplage de trois algorithmes d'apprentissage automatique, ANN, SVM et PCA **Erreur ! Source du renvoi introuvable.** Pour le réglage des relais de protection, il est possible d'utiliser une approche de RL multi-agents **Erreur ! Source du renvoi introuvable.** Une autre méthode de détection et de classification des défauts est basée sur *convolutional sparse autoencoder* **Erreur ! Source du renvoi introuvable.**

### **Conclusion**

Pour les différentes tâches en lien avec la conduite du réseau de distribution, les techniques d'IA les plus appropriées reposent sur des algorithmes d'apprentissage profond, ou *deep learning* (par exemple *deep belief networks*, *convolutional neural networks*, *multilayer perceptron neural networks* et *radial basis function networks*) et de *reinforcement learning* (comme le *Q-learning*, *actor-critic algorithm*, etc.). Ces algorithmes se retrouvent régulièrement dans des publications scientifiques récentes, avec des précisions acceptables, et des performances comparées qui dépendent essentiellement des données à disposition (en qualité et volume notamment) et de la taille du problème (donc indirectement sa complexité pour l'outil d'intelligence artificielle).

De fait, que ce soit DL ou RL, de grandes quantités de données sont nécessaires et ont tendance à faire augmenter la précision des résultats. En outre, les données doivent être diversifiées, sinon la capacité d'apprentissage de l'algorithme sera faible (par exemple, formé sur les données d'été seulement, un algorithme de prévision ne peut pas fonctionner efficacement les jours d'hiver). Le volume final des données requis dépend de leur représentativité, du niveau de performance souhaité, de la complexité du problème et des algorithmes appliqués.

Enfin, une tendance peut être notée, proposant très souvent l'utilisation couplée de plusieurs méthodes pour bénéficier des avantages de chacune dans des implémentations hybrides. Par conséquent, les solutions les plus efficaces pour les tâches d'exploitation du réseau électrique seront très probablement des combinaisons de plusieurs algorithmes, dont certains basés sur de l'IA et d'autres non. L'objectif étant toujours la performance de l'outil, mais sous contrainte d'industrialisation et de passage à l'échelle.



## REFERENCES

- [1] L. P. Kaelbling, M. L. Littman, A. W. Moore, "Reinforcement Learning: A Survey," *Journal of Artif. Intelligence Research* 4, pp. 237-285, May 1996.
- [2] X. S. Dong, L. J. Qian, and L. Huang, "Short-term load forecasting in smart grid: a combined CNN and K-means clustering approach," in *IEEE International Conference on Big Data and Smart Computing (BigComp)*, Jeju, Korea, Feb. 13–16, 2017.
- [3] Y. S. He, J. H. Deng, and H. J. Li, "Short-term power load forecasting with deep belief network and copula models," in *2017 9th International Conference on Intelligent Human-Machine Systems and Cybernetics*, Hangzhou, China, Aug. 26–27, 2017.
- [4] T. Hossen, S. J. Plathotam, R. K. Angamuthu et al., "Short-term load forecasting using deep neural networks (DNN)," presented at *2017 North American Power Symposium (NAPS)*. [Online]. Available: <https://engineering.und.edu/electrical/faculty/prakashranganathan/p232.pdf>
- [5] S. Hosein and P. Hosein, "Load forecasting using deep neural networks," *IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)*, Washington, DC, USA, 23-26 April 2017.
- [6] A. Dedinec, S. Filiposka, A. Dedinec, and L. Kocarev, "Deep belief network based electricity load forecasting: An analysis of the Macedonian case," *Energy*, vol. 115, part 3, pp. 1688–1700, Nov. 2016.
- [7] X. Qiu, L. Zhang, Y. Ren, P. N. Suganthan, and G. Amaratunga, "Ensemble deep learning for regression and time series forecasting," in *2014 IEEE Symposium on Computational Intelligence in Ensemble Learning (CIEL)*, 2014, pp. 1–6.
- [8] X. Peng, F. L. Pan, Y. C. Liang et al., "Fault detection algorithm for power distribution network based on sparse self-encoding neural network," in *2017 International Conference on Smart Grid and Electrical Automation (ICSGEA)*, Changsha, China, May 27–28, 2017.
- [9] P. E. A. Cardoso, "Deep learning applied to PMU data in power systems," Ph.D. thesis, *Faculdade De Engenharia Da Universidade Do Porto*, 2017.
- [10] C. Bulac, I. Trisiu, A. Mandi, L. Toma "On-line Power Systems Voltage Stability Monitoring using Artificial Neural Networks", the 9th international symposium on advanced topics in electrical engineering May 7-9, 2015 Bucharest, Romania.
- [11] Y. Gao, J. Shi, W. Wang, and N. Yu, "Dynamic distribution network reconfiguration using reinforcement learning," in *IEEE SmartGridComm*, Oct. 2019, pp. 1–7.
- [12] Q. Yang, G. Wang, A. Sadeghi, G. B. Giannakis, and J. Sun, "Two-timescale voltage control in distribution grids using deep reinforcement learning," *IEEE Trans. Smart Grid* (to appear); See also arXiv:1904.09374, 2019.
- [13] Axelberg P.G.V., Gu.I.Y.H., Bollen M.H.J., "Support vector machine for classification of voltage disturbances," *IEEE Transactions on Power Delivery*, vol. 22, no.3, pp. 1297-1303, 2007.
- [14] K. Chen, Jun Hu, Y. Zhang, Z. Yu and J. He., "Fault Location in Power Distribution Systems via Deep Graph Convolutional Networks", *IEEE Journal on Selected Areas in Communications*, 06 November 2019.
- [15] D. Thukaram, H. P. Khincha, and H. P. Vijaynarasimha, "Artificial neural network and support vector machine approach for locating faults in radial distribution systems," *IEEE Trans. Power Del.*, vol. 20, no. 2, pp. 710–721, Apr. 2005.
- [16] Wu, D., Zheng, X., Kalathil, D., & Xie, L. (2019a). Nested reinforcement learning based control for protective relays in power distribution systems, arXiv:1906.10815v1, August, 2019, (pp. 1–8), <https://arxiv.org/abs/1906.10815>.
- [17] J. Yan, H. He, X. Zhong, and Y. Tang, "Q-learning-based vulnerability analysis of smart grid against sequential topology attacks," *IEEE Trans. Inf. Forensics Security*, vol. 12, no. 1, pp. 200–210, Jan. 2017.
- [18] Belkacemi R., Abdulrasheed Babalola A., Zarrabian S. Real-Time Cascading Failures Prevention Through MAS Algorithm and Immune System Reinforcement Learning // *Electric Power Components*

and Systems. 2017. Vol. 45. No. 5. pp. 505-519.

[19] L. Guomin, T. Yingjie ; Y. Changyuan ; L. Yinglin ; H. Jinghan Deep learning-based fault location of DC distribution networks // The Journal of Engineering ( Volume: 2019 , Issue: 16 , 3 2019 ) pp. 3301 – 3305.

[20] K. Chen, J. Hu, and J. He, “Detection and classification of transmission line faults based on unsupervised feature learning and convolutional sparse autoencoder,” IEEE Trans. Smart Grid, pp. 1748 – 1758, 09 August 2016.

[21] Sajjan KS, Kumar V, Tyagi B. Genetic algorithm based support vector machine for on-line voltage stability monitoring. Int J Electr Power Energy Syst 2015;73:200–8.

[22] Hashemi S, Aghamohammadi MR. Wavelet based feature extraction of voltage profile for online voltage stability assessment using RBF neural network. Int J Electr Power Energy Syst 2013;49:86–94.

[23] Salkuti, S.R. Short-term electrical load forecasting using radial basis function neural networks considering weather factors. Electri. Eng. 2018, 5, 1–11.

[24] X. Dong, L. Qian, and L. Huang, “A CNN based bagging learning approach to short-term load forecasting in smart grid,” in Proc. IEEE SmartWorld, Ubiquitous Intell. Comput., Adv. Trusted Comput., Scalable Comput. Commun., Cloud Big Data Comput., Internet People Smart City Innov. Aug. 2017, pp. 1–6.

[25] S. Chan, I. Oktavianti, V. Puspita, A Deep Learning CNN and AI-Tuned SVM for Electricity Consumption Forecasting: Multivariate Time Series Data. 2019 IEEE 10th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON), 19 December 2019

[26] Z. S. Hosseini, M. Mahoor, and A. Khodaei, “AMI-enabled distribution network line outage identification via multi-label SVM,” IEEE Trans. Smart Grid, vol. 9, no. 5, pp. 5470–5472, Sep. 2018.

[27] Y.Aslan, Y.E.Yağan, “Artificial neural-network-based fault location for power distribution lines using the frequency spectra of fault data”. ElectrEng (2016).

[28] M. Pourahmadi-Nakhli and A. A. Safavi, “Path characteristic frequency-based fault locating in radial distribution systems using wavelets and neural networks,” IEEE Trans. Power Del., vol. 26, no. 2, pp. 772–781, Apr. 2011.

[29] W. Wang, N. Yu, Y. Gao , J. Shi. Safe Off-policy Deep Reinforcement Learning Algorithm for Volt-VAR Control in Power Distribution Systems. IEEE Transactions on Smart Grid, 27 December 2019.

[30] Trend Teknolojiler ve Finansal Aracı Kurumlara Etkileri II – Yapay Zeka ve Machine Learning. URL: <https://muzaffer kaleli.com>

[31] Understanding Recurrent Neural Networks: The Preferred Neural Network for Time-Series Data. Towards Data Science, Jun 2017. URL: <https://towardsdatascience.com>

## Les auteurs




**Aleksandr Petrushev** a obtenu sa licence " Relay Protection and Automation" de l'université Polytechnique de Tomsk (TPU) en 2017 et 2 masters en génie électrique de l'Institut Polytechnique de Grenoble et TPU en 2019. La même année, il a commencé son doctorat à G2ELab, en France. Ce travail est dédié au développement d'outils basés sur l'intelligence artificielle pour la gestion des réseaux électriques intelligents, tels que i) les réseaux de neurones ii) l'apprentissage par renforcement.



**Vincent Debusschere** a obtenu son doctorat en écoconception des machines électriques à l'École normale supérieure de Cachan en 2009. Il a rejoint le Laboratoire de Génie Electrique G2ELab en 2010, sur un poste de Maître de Conférences de Grenoble INP. Il a passé son HDR en 2019 après avoir été "visiting associate professor" à NTU Singapour en 2018/2019. Ses recherches portent sur l'intégration des énergies renouvelables, la modélisation des leviers de flexibilité pour les réseaux intelligents, l'évaluation multicritères et la conception optimale de systèmes complexes ainsi que les méthodes avancées pour le contrôle comme l'intelligence artificielle.



**Rémy Rigo-Mariani** est titulaire d'un doctorat de l'INP Toulouse depuis 2014. Il a travaillé en tant que chercheur postdoctorant à l'Université de Washington, Seattle, USA, avant de rejoindre le *Cambridge Advance Research Centre for Education (CARES)* et l'*Energy Research Institute at Nanyang Technological University (ERI@N)* à Singapour. Il est depuis 2020 chargé de recherche au CNRS, au laboratoire G2Elab, dans l'équipe réseaux et systèmes. Ses axes de recherche couvrent i) l'intégration de sources d'énergie distribuées dans les réseaux, ii) l'opération et dimensionnement de systèmes multi-énergies, iii) ainsi que les marchés émergents de l'électricité et la valorisation des ressources flexibles.



**Patrick Reignier** a obtenu un doctorat en robotique en 1994. Après un premier poste de Maître de Conférence à l'ENI de Brest sur le thème de la réalité virtuelle, il rejoint l'Université Joseph Fourier en 2000. Il passe son HDR en 2010 et devient Professeur à Grenoble INP en 2011. Il est actuellement directeur adjoint du laboratoire LIG. Ses travaux de recherche concernent l'intelligence ambiante, croisement de l'informatique ubiquitaire et de l'intelligence artificielle.



**Nouredine Hadjsaid** est Professeur à Grenoble INP, Directeur du Laboratoire d'Ingénierie Electrique de Grenoble (G2ELAB). Il a été professeur invité à Virginia Tech (USA) et NTU (Singapour). Ses recherches portent sur les réseaux électriques intelligents, qui comprennent de la production distribuée, les technologies de l'information et de la communication, et la sécurité et stabilité des réseaux électriques, entre autres.

## Résumé

Le contrôle opérationnel du réseau de distribution repose traditionnellement sur des systèmes experts. Avec l'intégration croissante de ressources d'énergie distribuée à base renouvelables, le comportement des nouveaux types de consommateurs d'énergie, le volume de données disponibles permet d'imaginer un support d'outils basés sur l'intelligence artificielle (IA) afin d'améliorer la pertinence des outils à la disposition des gestionnaires de réseaux. En plus de l'augmentation du volume de données, la capacité des serveurs de calculs (centralisés ou distribués) permet désormais d'envisager l'IA pour un large éventail de tâches. Cet article présente les principales catégories d'IA en fonction des applications potentielles pour les réseaux de distribution. Ces applications couvrent des tâches telles que le contrôle de la tension, de la puissance, la reconfiguration et les systèmes de conseil, de diagnostic et d'interprétation de fonctionnement. Une conclusion est proposée sur les techniques les plus intéressantes à l'heure actuelle et les moyens à mettre en place pour se les approprier.

## Abstract

Operational planning and management of distribution network typically relies on expert systems and model-based controllers. With the increasing integration of renewable based energy sources, new electricity usages arise with the concept of prosumers that denotes the ability of end user to consume or produce energy. Also, the quantity and variety of the data available today, along with increased computational capabilities, open the door to the investigation of novel tools based on artificial intelligence (AI), as a support to network operators. The article then presents the main AI driven techniques and their potential interest to address typical network applications – voltage and transformer loading regulation, network reconfigurations, diagnostics. A generic implementation of AI-based controllers is proposed and the article concludes on the techniques that seems the most appropriate today and how to handle them.

## Proposition Bandeau (voir zip joint)

### Proposition Phrases Accroche

- 1) De nouvelles méthodes pour de nouvelles missions des gestionnaires de réseaux.
- 2) Les données au service du réseau.
- 3) Intelligence artificielle pour les réseaux électriques intelligents