

Modèle Prédicatif de Machine Learning pour la Modélisation des Sources Harmoniques

Meriem ZANOUN^{1,2}, Eric LABOURE¹, Mohamed BENSETTI¹, Trung Dung LE¹, Xavier YANG², Sébastien GOURAUD²

¹ Université Paris-Saclay, CentraleSupélec, CNRS, Laboratoire de Génie Electrique et Electroniques de Paris,
91192, Gif-sur-Yvette, France

Sorbonne Université, CNRS, Laboratoire de Génie Electrique et Electronique de Paris,
75252, Paris, France

²EDF R&D Lab Paris-Saclay,
91120, Palaiseau, France

RESUME - Avec l'essor des énergies renouvelables et la croissance des convertisseurs électroniques de puissance, les perturbations harmoniques augmentent, affectant ainsi la qualité de l'électricité. Ce papier présente une nouvelle méthodologie de modélisation basée sur l'apprentissage automatique, entraînée sur des bases de données issues de mesures de laboratoire, pour prédire le courant harmonique. Un modèle utilisant les données des chargeurs de véhicules électriques montre des performances prometteuses. L'intégration de ces modèles dans les réseaux basse tension améliore la simulation dans le domaine fréquentiel et renforce l'analyse du réseau.

Mots-clés—Électronique de puissance, Machine learning, Génération harmoniques, Simulation fréquentielle, Réseaux de distribution, Mesures expérimentales.

1. INTRODUCTION

Garantir une alimentation électrique de qualité est crucial pour le bon fonctionnement des équipements dans les réseaux électriques, qu'ils soient publics ou privés. Toutefois, la gestion des harmoniques et supra-harmoniques [1], [2] représente un défi majeur, car elles perturbent la stabilité, la fiabilité et le vieillissement des équipements, et ce, malgré les normes [3], [4], [5] existantes visant à limiter leurs émissions sur le réseau. L'augmentation des distorsions harmoniques résulte de plusieurs facteurs, notamment la transition vers des énergies renouvelables et l'électrification croissante des usages [6]. Les réseaux de distribution basse tension (BT) sont particulièrement impactés par la prolifération des chargeurs de véhicules électriques, des systèmes solaires, des pompes à chaleur et des appareils ménagers, qui génèrent des courants harmoniques en s'interfaçant avec le réseau via des convertisseurs électroniques de puissance (PE) dont le comportement est non linéaire. Ces courants dégradent la qualité de la tension et du courant et, en interaction avec d'autres dispositifs, peuvent amplifier les harmoniques, créant ainsi une instabilité supplémentaire du réseau [7]. Par conséquent, une estimation précise de ces perturbations est essentielle pour limiter leur impact sur les systèmes électriques.

Deux approches principales de modélisation des harmoniques sont utilisées : l'approche temporelle et l'approche en domaine fréquentiel. La première [8] permet de tester avec précision le comportement des convertisseurs électroniques sous différentes conditions de réseau, mais elle présente des inconvénients liés à

la confidentialité des données techniques des fabricants et à la lourdeur des calculs. Tandis que l'approche en domaine fréquentiel [9], plus rapide, modélise les harmoniques en utilisant une source de courant constant à multiples fréquences, mais ne parvient pas à rendre compte du comportement harmonique des charges modernes, qui sont davantage influencées par la tension et l'impédance du réseau [10].

Des recherches récentes ont exploré des approches hybrides combinant les domaines temporel et fréquentiel pour améliorer la modélisation de la qualité de l'alimentation. Cependant, ces méthodes [11],[12],[13] n'ont pas spécifiquement abordé la prédiction des courants harmoniques en fonction des conditions du réseau.

Dans nos travaux précédents, [14] nous avons exploré le comportement non linéaire de différents convertisseurs PE et montré que les courants harmoniques générés par un convertisseur spécifique au point de connexion sont intrinsèquement liés à la tension harmonique et à l'impédance fréquentielle du réseau. De plus, [15] a introduit une méthode novatrice qui construit un modèle d'apprentissage automatique pour prédire les harmoniques de courant en utilisant une base de données générée à partir de simulations en domaine temporel, évaluant diverses techniques d'apprentissage automatique basées uniquement sur la tension efficace (RMS) et la tension crête.

Dans cet article, notre objectif est de développer des modèles d'apprentissage automatique (Machine Learning (ML)) en traitant la charge non linéaire comme une boîte noire, sans avoir besoin d'une connaissance détaillée de sa structure interne. Ces modèles visent à prédire les harmoniques de courant non seulement pour un convertisseur individuel, mais également dans des scénarios réels où plusieurs convertisseurs interagissent au sein du réseau basse tension, comme illustré à la Fig. 1. L'objectif est d'adresser cette complexité en intégrant ces modèles dans des simulations fréquentielles itératives harmoniques. Cette approche surmonte les limitations des modèles traditionnels de source de courant statique, qui échouent à prédire avec précision les harmoniques de courant en raison de leur incapacité à prendre en compte les configurations du réseau.

Le reste de l'article est structuré comme suit : tout d'abord, nous présentons la méthodologie pour la modélisation des convertisseurs, y compris les explications sur le processus de

mesures de laboratoire pour construire une base de données représentative qui décrit précisément le comportement du dispositif. Ensuite, nous décrivons le processus d'entraînement et d'évaluation de plusieurs modèles robustes de ML dans différents scénarios, en utilisant des métriques pertinentes pour assurer leur capacité à prédire les courants harmoniques dans des conditions variables du réseau. Le cas d'étude choisi pour ce travail est un chargeur de véhicule électrique (EV) [16]. Enfin, nous discutons des résultats obtenus et formulons quelques conclusions.




Figure 1- Schéma de la structure du réseau avec plusieurs charges non linéaires

2. METHODOLOGIE

2.1. Modèle de convertisseur avec ML

Les recherches récentes révèlent une adoption croissante de l'intelligence artificielle (IA) pour relever divers défis liés aux réseaux, tels que la détection de défauts ou encore la prédiction de la consommation d'électricité [16], [17]. Dans le cadre de cette étude, nous visons à prédire les courants harmoniques, notamment leur amplitude et leur angle de phase, en fonction de paramètres clés du réseau, comme la tension, la puissance et l'impédance (Fig. 2). Pour ce faire, nous utilisons des modèles de ML qui exploitent différents algorithmes statistiques afin d'analyser les ensembles de données et de capturer les relations non linéaires complexes entre les grandeurs électriques des convertisseurs. La formulation correcte du problème est essentielle pour sélectionner l'approche ML la plus adaptée. Parmi les catégories principales identifiées dans la littérature, on retrouve l'apprentissage supervisé (régression ou classification), l'apprentissage non supervisé et l'apprentissage par renforcement. Étant donné que notre objectif est de prédire des valeurs numériques continues, nous traitons ce problème comme une tâche de régression supervisée [18].




Figure 2- Entrées/Sorties du modèle Machine Learning

Avant d'entraîner un modèle ML il est crucial de disposer d'un jeu de données représentatif du phénomène à modéliser. Dans cette première section, nous décrivons le processus de construction d'un jeu de données adapté à notre cas d'étude. Dans la deuxième section, nous explorons trois méthodes de ML adaptées à la modélisation des sources harmoniques. Ces méthodes sont entraînées sur une portion significative des données expérimentales issues de mesures en laboratoire, réalisées sous différentes conditions de tension harmonique et d'impédance. Les modèles sont ensuite testés sur des scénarios de données non vus afin d'évaluer leur robustesse et leur précision. Les performances sont évaluées à l'aide de plusieurs métriques, qui seront détaillées dans la troisième section.

2.2. Construction de la Base de données

La première étape pour construire un modèle de ML est de disposer des données nécessaires. Cette section sera dédiée à l'explication du processus de création de la base de données (BdD) (Fig. 3, Fig. 4), qui repose sur des mesures réelles. Celles-ci ont été effectuées en alimentant le convertisseur étudié dans différents scénarios de tension, avec diverses configurations d'impédance en amont et de points de fonctionnement.

Ce procédé repose sur les éléments suivants :

- Un générateur de signaux de tension harmonique génère des signaux dans une plage de 0 à 10 V. Ces signaux sont ensuite amplifiés à l'aide d'un amplificateur de puissance pour alimenter l'équipement sous test.
- Les signaux à injecter sont définis à partir d'un fichier texte (.txt), où chaque ligne correspond à un scénario spécifique à injecter. Les colonnes indiquent respectivement l'ordre harmonique, l'amplitude (%) et l'angle de phase (°) de l'harmonique concerné.
- Pour chaque scénario, l'amplitude de la tension harmonique U_h est une valeur aléatoire comprise entre 0 et la limite d'émission U_{hmax} , telle que définie par le standard EN50160, tandis que la phase φ_h est une valeur aléatoire comprise entre 0° et 360° .

Nous veillons à ce que les limites ne soient dépassées ni pour chaque harmonique individuellement, ni pour la distorsion harmonique totale (THDv) dans son ensemble.




Figure 3- Schéma du banc de test

Ce processus est répété pour différentes impédances amont, l'inductance amont étant réglable. Dans notre cas, trois valeurs d'inductance ont été testées : 100 μH , 400 μH et 800 μH , avec une résistance de ligne de référence. Ces valeurs ont été choisies en fonction du matériel disponible au laboratoire, des mesures ont été réalisées pour chacune de ces configurations d'inductance.




Figure 4 – Process de construction de la BdD

Chaque scénario est exécuté pendant 2 secondes, et entre deux scénarios, un signal sinusoïdal est appliqué afin d'éviter l'apparition de transitoires importants. Les formes d'onde temporelles de courant et de tension au point de connexion (POC) sont enregistrées pour chaque scénario durant les 200 dernières millisecondes, ce qui correspond à 10 périodes à 50Hz, conformément à la norme IEC 61000-4-7, afin de garantir des conditions en régime permanent. Une transformation de Fourier rapide (FFT) est ensuite appliquée, et les harmoniques de tension et de courant sont sauvegardés sous forme tabulaire, en tant que données sous forme de nombres complexes.

3. MODELES MACHINE LEARNING

3.1. Réseaux de neurones

Un réseau de neurones pour la régression (RNN) est un type de réseau de neurones artificiels (ANN) conçu pour prédire des valeurs de sortie continues (Fig. 5). Il est composé de couches de neurones interconnectés a_j , où chaque neurone traite les données en entrée à l'aide de poids w_{ij} et de biais b_j , puis applique une fonction d'activation f pour produire une sortie. L'apprentissage du réseau consiste à ajuster les poids en fonction de l'erreur entre la valeur prédite et la valeur réelle.

Ce mécanisme permet au réseau d'apprendre des relations complexes et de détecter des relations non linéaires dans les données, ce qui le rend particulièrement adapté aux cas où une régression linéaire classique échoue à capturer les dépendances non linéaires, comme c'est le cas pour les phénomènes harmoniques.

$$a_j = f\left(\sum_{i=1}^n w_{ij} \cdot x_i + b_j\right), \hat{y} = \sum_{j=1}^k v_j a_j + c$$

Dans notre cas d'étude, chaque variable de sortie $\hat{y}$ à prédire est prise en charge par un réseau de neurones distinct. L'objectif est de prédire les courants harmoniques impairs jusqu'au 25 rang [1, 3, 5...25], ce qui représente 13 rangs. Étant donné que chaque ordre comprend à la fois une amplitude et un angle de phase, nous devons modéliser deux variables par ordre, soit un total de 26 variables à prédire. Par conséquent, nous concevons autant de modèles que de variables à estimer.




Figure 5 - Schéma d'un réseau de neurones pour la régression avec une couche cachée

3.2. Arbres de décision

Un arbre de régression (TREE) est une méthode d'apprentissage supervisé non paramétrique, utilisée pour résoudre des problèmes de régression. Son principe repose sur une partition récursive des données d'entrée en sous-ensembles, à partir de la valeur d'un attribut à la fois un peu à la manière d'une série de questions successives. Chaque nœud de l'arbre correspond à un test sur un attribut, chaque branche représente un résultat possible de ce test, et chaque feuille fournit une valeur prédite. L'objectif de l'arbre est de minimiser l'incertitude mesurée par l'erreur quadratique moyenne (MSE) ou l'erreur absolue moyenne (MAE) et de maximiser le gain d'information à chaque division.

Malgré leur simplicité et leur caractère interprétable, les arbres de régression peuvent présenter une certaine instabilité et être sujets au surapprentissage. Toutefois, lorsqu'ils sont correctement paramétrés et encadrés, ils constituent des outils puissants pour la prédiction dans de nombreux domaines.

La Fig. 6 illustre la structure hiérarchique typique d'un arbre de décision, partant d'un nœud racine, se scindant en nœuds internes, puis aboutissant à des nœuds feuilles.




Figure 6 - Structure typique d'un arbre de décision

3.3. Forêts aléatoires

Une forêt aléatoire (Random Forest, RF) est une technique d'apprentissage par ensemble qui combine plusieurs arbres de décision afin d'améliorer la précision des prédictions et de limiter le surapprentissage (Fig. 7). Chaque arbre est entraîné sur un échantillon bootstrap différent des données, et à chaque nœud, une sous-partie aléatoire des variables est utilisée pour déterminer la meilleure division. Cette approche permet de réduire la variance du modèle.

La prédiction finale est obtenue en moyennant les résultats de tous les arbres individuels, ce qui rend le modèle plus robuste face au surapprentissage et améliore sa capacité de généralisation sur des données non vues. Bien qu'augmenter le nombre d'arbres améliore généralement les performances, cela se fait au prix d'un temps de calcul plus élevé. La RF est particulièrement efficace pour les tâches de régression complexes, car elle offre un bon compromis entre interprétabilité et puissance prédictive.




Figure 7 - Architecture d'une forêt aléatoire

4. CRITERES DE PERFORMANCES DES MODELES

Après avoir sélectionné le convertisseur, construit la BdD, et entraîné les modèles d'apprentissage automatique à l'aide des méthodes choisies, nous procédons à l'analyse des résultats en calculant les erreurs sur les amplitudes et les angles de phase des courants harmoniques prédits. Pour permettre une interprétation efficace des performances, trois métriques d'évaluation ont été utilisées

4.1. MAPE – Erreur moyenne absolue en pourcentage

Cette métrique exprime l'erreur relative en pourcentage entre les valeurs réelles et prédites des amplitudes des courants harmoniques de rang h .

$$MAPE_h = \frac{100\%}{n} \sum_{i=1}^n \frac{|I_{hi} - \hat{I}_{hi}|}{|I_{hi}|} \quad (1)$$

Avec n : nombre total d'échantillons, h : rang harmonique, I_h : amplitude cible du courant de rang h , $\hat{I}_h$: amplitude prédite du courant de rang h .

4.2. MAE – Erreur absolue moyenne

Cette métrique mesure l'erreur absolue entre les angles de phase des courants réels et prédits de rang h , exprimée en degré.

$$MAE_h = \frac{1}{n} \sum_{i=1}^n |\varphi_{hi} - \hat{\varphi}_{hi}| \quad (2)$$

Avec φ_h : angle de phase cible du courant de rang h ; $\hat{\varphi}_h$: angle de phase prédit du courant de rang h .

4.3. RRMSE – Erreur quadratique moyenne relative

Contrairement aux deux métriques précédentes, qui s'appliquent au domaine fréquentiel, celle-ci mesure l'erreur sur les formes d'onde reconstruites dans le domaine temporel.

$$RRMSE = 100\% \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (I(t)_i - \hat{I}(t)_i)^2}}{\sqrt{\frac{1}{n} \sum_{i=1}^n I(t)_i^2}} \quad (3)$$

Avec $I(t)$: courant cible en domaine temporel

$\hat{I}(t)$: courant prédit en domaine temporel

5. INTEGRATION DU MODELE ML SUR UN RESEAU BT

L'objectif est de réaliser une analyse de flux de puissance harmonique (HLF) dans les réseaux électriques, en prenant en compte les harmoniques générés par une charge non linéaire modélisée à l'aide d'un modèle ML, afin d'évaluer la pertinence de la méthode proposée dans le système et de vérifier sa convergence [19].

Les objectifs principaux de l'analyse HLF sont les suivants : quantifier les niveaux harmoniques, tels que la distorsion harmonique totale (THD), évaluer l'impact aux différents points du réseau, et concevoir des solutions de mitigation efficaces, par exemple, l'ajout de filtres pour atténuer les effets des harmoniques. Cette analyse harmonique peut être réalisée à l'aide d'outils industriels tels que PowerFactory ou OpenDSS, en s'appuyant sur différents algorithmes de résolution, notamment Newton-Raphson, Fast Decoupled Power Flow, ou encore la méthode de balayage direct/inverse (Backward/Forward Sweep, BFS).

5.1. Modélisation des composants du réseau

Afin de simplifier la validation de nos modèles ML, conçus comme des boîtes noires à l'aide de la toolbox Matlab et intégrés dans un réseau électrique via une simulation itérative en domaine fréquentiel, nous avons dans un premier temps choisi de modéliser le réseau sous Simulink, les deux outils étant basés sur l'environnement Matlab. Toutefois, une intégration future dans un outil industriel reste tout à fait envisageable.

Bien que Simulink soit initialement destiné à des simulations en domaine temporel, nous avons modélisé les composants du

réseau dans le domaine fréquentiel, et mené des simulations fréquentielles afin de valider la précision des modèles ML.

Ce processus fonctionne de manière similaire à un algorithme de balayage direct/inverse (BFS) : la tension est d'abord propagée à travers le réseau, la charge modélisée par le modèle ML est alimentée, et le courant correspondant est retourné. Ce courant remonte ensuite dans le réseau à travers l'impédance des lignes, déformant la tension, qui devient à son tour la nouvelle entrée du modèle ML. Ce cycle se poursuit jusqu'à ce que le modèle retourne le même courant sur plusieurs itérations consécutives, marquant ainsi la convergence du processus.




Figure 8 - Modèle ML intégré dans Matlab/simulink pour une simulation fréquentielle

Il s'agit en effet d'un calcul itératif basé sur une analyse fréquentielle, pour les raisons suivantes :

- La forme d'onde de la tension est mesurée puis décomposée en série de Fourier (FFT), ce qui nécessite une fenêtre temporelle minimale de 20 ms.
- À partir de cette décomposition harmonique de la tension, le courant harmonique est prédit par le modèle ML. Une fois cette étape réalisée, une transformation de Fourier inverse (IFFT) est appliquée pour reconstruire la forme d'onde du courant dans le domaine temporel.
- Ce courant est ensuite injecté dans le réseau.
- La tension du réseau est alors perturbée.
- Le processus est répété à la période suivante jusqu'à stabilisation de la solution.

6. RESULTATS

6.1. Validation des modèles ML avec des mesures de laboratoire

Nous présentons ici les résultats de l'application des techniques ML à la modélisation d'un chargeur de véhicule électrique, qui convertit le courant alternatif du réseau en courant continu pour recharger la batterie du véhicule, à l'aide d'un redresseur spécifique constituant une charge non linéaire.

L'étude a consisté à entraîner les trois techniques de ML : RNN, TREE et RF. Ces modèles ont ensuite été testés sur un même jeu de test représentant 20 % de l'ensemble des données, soit environ 3000 échantillons. Ces échantillons correspondent à 3000 scénarios différents de tension d'alimentation, et sont synthétisés à la Fig. 9 sous forme de diagrammes en boîte à moustaches, illustrant les variations des amplitudes et des phases injectées, ainsi que du courant fourni par le chargeur VE.

Notre analyse met en évidence une corrélation significative entre les courants harmoniques du chargeur et la tension d'alimentation.




Figure 9 - (a) Variations des amplitudes et angles de phase de la tension d'alimentation et (b) du courant mesuré

Les modèles ont été évalués à l'aide de plusieurs métriques. Parmi les trois approches, le modèle RNN a présenté les taux d'erreur les plus faibles pour l'ensemble des indicateurs, suivi du modèle RF, puis du modèle TREE, comme illustré à la Fig. 10.

Les performances supérieures du modèle RF par rapport à TREE étaient attendues, la RF reposant sur une approche par ensemble qui améliore les performances des arbres de décision pris individuellement.

En comparaison, le modèle RNN a surpassé la RF, probablement en raison de sa capacité accrue à capturer les relations non linéaires présentes dans les données. Le RNN a atteint une MAPE inférieure à 8 % pour la prédiction des amplitudes, et un MAE inférieur à 10° pour les prédictions d'angles de phase.

Concernant la RRMSE, les trois modèles présentent des performances comparables, bien que le RNN reste en tête avec des erreurs inférieures à un maximum de 3 %, comme représenté à la Fig.11.




Figure 10 - Erreurs MAPE et MAE sur les amplitudes et phases prédites par le modèle ML




Figure 11 - Erreur RRMSE sur les formes d'onde de courant pour les trois techniques

Sur la base de ces résultats, le modèle RNN a été sélectionné pour une analyse approfondie, en raison de sa précision supérieure dans la capture des caractéristiques non linéaires des données issues du chargeur de véhicule électrique.

Nous avons représenté à la Fig. 12 les meilleurs et pires échantillons en termes de RRMSE, et nous avons également analysé le spectre fréquentiel ainsi que la forme d'onde des courants cibles et prédits.




Figure 12 - Représentation temporelle et fréquentielle du meilleur (a, b) et du pire (c, d) courant prédit par le modèle RNN

6.2. Intégration sur HLF

Nous avons validé l'approche à l'aide d'un réseau basse tension (BT) simplifié ($U_n = 400V$) connecté à un poste source moyenne tension (HTA) de 20 kV. Dans cette configuration, illustrée dans la Fig. 13, il est possible de contrôler la tension d'alimentation, qu'elle soit polluée par des harmoniques ou parfaitement sinusoïdale.

Le réseau HTA est relié à un transformateur abaisseur de tension vers le niveau BT, lequel est ensuite connecté au modèle ML du chargeur EV via une ligne BT. L'impédance équivalente du réseau est proche de celle utilisée lors des mesures en laboratoire.

Le modèle ML est intégré dans Simulink à l'aide du bloc *Regression Neural Network Predict*.




Figure 13 - Schéma Simulink du réseau BT étudié

L'évolution du courant au fil des itérations est illustrée dans la Fig.14. Il est important de noter que chaque période représente une itération. Lors de l'itération initiale, les formes d'onde présentent des fluctuations notables. Toutefois, après environ cinq itérations, les signaux convergent progressivement.

Dans la mesure où nous ne disposons pas de la forme d'onde réelle du courant généré par la charge non linéaire, nous avons comparé le résultat convergé à la forme d'onde la plus proche issue de la base de données, afin de valider la précision du modèle.

La Fig. 15 montre que, bien que les signaux ne soient pas strictement identiques, ils sont très proches, ce qui constitue un indice qualitatif satisfaisant quant à la fidélité de la prédiction de la forme d'onde.




Figure 14 - Évolution du courant au POC au fil des itérations




Figure 15- Comparaison des formes d'onde de courant et de tension issues de la simulation avec les formes d'onde de référence

7. CONCLUSION

Cette étude a présenté une méthodologie innovante pour la modélisation des convertisseurs électroniques de puissance. L'approche proposée repose sur l'exploitation de techniques de machine learning, intégrant des données issues de mesures en laboratoire pour représenter les charges non linéaires sous forme de modèle boîte noire. Trois modèles d'apprentissage automatique ont été comparés et évalués à l'aide de plusieurs métriques. Les résultats ont démontré que le métamodèle RNN permet de reproduire fidèlement les relations non linéaires du courant généré par le convertisseur PE, testé dans le cadre d'un chargeur de véhicule électrique.

L'intégration du modèle ML validé dans un réseau BT simplifié, via une simulation itérative hybride temporel/fréquentiel, a confirmé la pertinence de l'approche pour les études de qualité d'électricité.

Les travaux futurs consisteront à complexifier le réseau BT, en ajoutant notamment des condensateurs ainsi que plusieurs modèles MLM, en parallèle à d'autres charges linéaires et non linéaires, afin d'évaluer la convergence du système en utilisant le même outil de simulation. Par ailleurs, une intégration du modèle ML dans des outils industriels dédiés à l'analyse des flux de puissance harmonique (HLF) est en cours, afin d'évaluer la convergence du système dans des contextes de réseaux réels.

Enfin, nous prévoyons de modéliser d'autres types de charges non linéaires, telles que les pompes à chaleur, les lampes LED, des convertisseurs DC-DC ou les téléviseurs, pour élargir l'étude et explorer la faisabilité de notre approche sur une variété de charges. Ce travail futur pourra également inclure une classification des charges en fonction de leur faisabilité de modélisation et de leur tolérance à l'erreur dans ce cadre méthodologique.

8. REFERENCES

- [1] R. Ott, "Qualité de la tension - Harmoniques", Techniques de l'ingénieur, Réf: D4264 V1 2002.
- [2] J. Schonek, "Les singularités de l'harmonique 3," Technical collection Schneider Electric n°202, 1999.

- [3] "Voltage characteristics of electricity supplied by public distribution networks," EN 50160.

- [4] "Compatibilité électromagnétique (CEM) Partie 3-12 : Limites – Limites pour les courants harmoniques produits par les appareils connectés aux réseaux publics basse tension ayant un courant appelé > 16 A et ≤ 75 A par phase."

- [5] "Compatibilité électromagnétique (CEM) - Partie 3-2: Limites - Limites pour les émissions de courant harmonique (courant appelé par les appareils 16 A par phase)."

- [6] J. H. R. Enslin and P. J. M. Heskes, "Harmonic Interaction Between a Large Number of Distributed Power Inverters and the Distribution Network," IEEE Trans. Power Electron., vol. 19, no. 6, pp. 1586–1593, Nov. 2004.

- [7] C. Collombet, J. M. Lupin, and J. Schonek, "Harmonic disturbances in networks, and their treatment", Technical collection Schneider Electric n°152, 1999.

- [8] Z. Guo et al., "Aggregate Harmonic Load Models of Residential Customers. Part 1: Time-Domain Models," in 2019 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe), Bucharest, Romania: IEEE, Sep. 2019, pp. 1–5.

- [9] Z. Guo et al., "Aggregate Harmonic Load Models of Residential Customers. Part 2: Frequency-Domain Models," in 2019 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe), Bucharest, Romania: IEEE, Sep. 2019, pp. 1–5.

- [10] X. Yang, X. Niu, and B. Paszkier, "Disturbance load modelling with equivalent voltage source method in grid harmonic assessment," 23rd International Conference on Electricity Distribution, June 2015.

- [11] J. Mazumdar, R. G. Harley, F. C. Lambert, G. K. Venayagamoorthy, and M. L. Page, "Intelligent Tool for Determining the True Harmonic Current Contribution of a Customer in a Power Distribution Network," IEEE Trans. on Ind. Applicat., vol. 44, no. 5, pp. 1477–1485, Sep. 2008.

- [12] A. Taghvaie, T. Warnakulasuriya, D. Kumar, F. Zare, R. Sharma, and D. M. Vilathgamuwa, "A Comprehensive Review of Harmonic Issues and Estimation Techniques in Power System Networks Based on Traditional and Artificial Intelligence/Machine Learning," IEEE Access, vol. 11, pp. 31417–31442, 2023.

- [13] A. Kalair, N. Abas, A. R. Kalair, Z. Saleem, and N. Khan, "Review of harmonic analysis, modeling and mitigation techniques," Renewable and Sustainable Energy Reviews, vol. 78, pp. 1152–1187, Oct. 2017.

- [14] A. Dada, E. Laboure, M. Bensetti, X. Yang, B. George, and M. Caujolle, "Machine Learning Metamodeling of Harmonic Sources in LV Distribution Networks," in 2022 20th International Conference on Harmonics & Quality of Power (ICHQP), Naples, Italy: IEEE, May 2022, pp. 1–6.

- [15] A. Dada, E. Labouré, M. Bensetti, X. Yang, F. Couronné, and M. Caujolle, "Enhanced machine learning methods for nonlinear harmonic source modelling," in CIRED 2021 - The 26th International Conference and Exhibition on Electricity Distribution, , Online Conference: Institution of Engineering and Technology, 2021, pp. 975–980.

- [16] A. Megha, N. Mahendran and R. Elizabeth, "Analysis of Harmonic Contamination in Electrical Grid due to Electric Vehicle Charging," 2020 Third International Conference on Smart Systems and Inventive Technology (ICSSIT), Tirunelveli, India, 2020, pp. 608-614.

- [17] A. Eslami, M. Negnevitsky, E. Franklin, and S. Lyden, "Review of AI applications in harmonic analysis in power systems," Renewable and Sustainable Energy Reviews, vol. 154, p. 111897, Feb. 2022.

- [18] R. Shwartz-Ziv and A. Armon, "Tabular data: Deep learning is not all you need," Information Fusion, vol. 81, pp. 84–90, May 2022.

- [19] J. Zhang, Q. Yao, R. Sun, H. Qin, and X. Dong, "The harmonic load flow calculation of distribution network with distributed power," in 2011 International Conference on Advanced Power System Automation and Protection, Beijing, China: IEEE, Oct. 2011.