

Optimisation du filtrage actif de la pollution du réseau par une commande intelligente

Serge Raoul DZONDE NAOUSSI*, Pierre Marie FENYOM et Salomé NDJAKOMO ESSIANE

Université de Douala, Ecole doctorale des sciences fondamentales et appliquées, Unité de Formation Doctorale des Sciences Appliquées, Laboratoire des Technologies et Sciences Appliquées, BP 8698 Douala, Cameroun

* Correspondance, courriel : *serge.dzonde@univ-douala.com*

Résumé

Ce travail porte sur l'optimisation du filtrage actif de la pollution du réseau par une commande neuronale. Nous développons une loi de commande dite intelligente qui a pour but d'optimiser le processus de filtrage des harmoniques de courant présents dans les réseaux électriques. L'optimisation est réalisée grâce à l'algorithme de rétropropagation du gradient utilisé pour entrainer des réseaux de neurones principalement de type perceptrons multicouches. Les résultats montrent que la loi de commande développée permet une adaptation aux variations de la charge non linéaire du réseau et donc aux fluctuations des perturbations harmoniques. Le THD du système pollué et modélisé, initialement de 31,71 % est finalement ramené à 1.85 % après compensation. Les résultats obtenus validés après simulations nous ont permis de conclure que notre travail est une amélioration des techniques de commande (classiques et modernes) existantes.

Mots-clés : harmoniques, filtre actif parallèle, réseaux de neurones artificiels, rétropropagation du gradient.

Abstract

Optimization of active filtering of network pollution by intelligent control

This work deals with the optimization of the active filtering of the network pollution by a neuronal control. We develop a so-called intellient control law that aims to optimize the process of filtering harmonics in the electrical networks. The optimization is carried out by the gradient retropropagation algorithm used as the learning process of the neural networks of multilayer perceptron type. The results show that the developed control law allows an adaptation to the variations of the non-linear load of the network and thus to the fluctuations of the harmonic disturbances. The THD of the polluted and modeled system, initially 31.71 % is finally reduced to 1.85 % after compensation. The results obtained validated after simulations allowed us to conclude that our work is an improvement of existing control techniques (classical an modern).

Keywords : harmonics, active power filter, artificial neural networks, gradient retropropagation.

1. Introduction

Les perturbations de courant et de tension dans les réseaux de distribution électrique sont causées par la prolifération des charges non linéaires, qui sont des appareils qui absorbent des courants non sinusoïdaux et introduisent de ce fait des pollutions harmoniques [1]. Les harmoniques ainsi engendrées circulent dans les réseaux électriques et perturbent le fonctionnement normal de certains équipements électriques pouvant même engendrer leur destruction [1, 2]. C'est pour ces raisons que le filtrage des distorsions en courant et en tension est au centre des préoccupations actuelles à la fois des fournisseurs et des utilisateurs d'énergie électrique. Pour des installations électriques existantes, les filtres actifs parallèles (FAP) sont à ce jour les solutions avancées de dépollution des courants harmoniques les plus adéquates [3 - 5]. Les FAP sont constitués de convertisseurs à base d'interrupteurs de puissance, de type onduleur, associés à un dispositif de contrôle et de commande adapté [6, 7]. Ils peuvent être assimilés à des sources de courant qui compensent directement les perturbations harmoniques en injectant sur le réseau des courants en opposition de phase par rapport aux perturbations mesurées [8]. Le FAP appelé aussi compensateur shunt, est connecté en parallèle sur le réseau électrique et procède par identification puis filtrage des harmoniques à rejeter. Plusieurs travaux dans la littérature ont été faits dans le sens de l'amélioration du filtrage actif, tant au niveau des méthodes d'identifications des courants de référence que sur la commande de l'onduleur du filtre actif [4, 9 - 11]. Parmi elles nous avons des méthodes classiques [9,10], des méthodes avancées [4, 6, 7-12] et des méthodes intelligentes [2-3, 5, 11, 13-16]. Ces dernières présentent encore des limites que nous tentons de résoudre dans ce papier par une technique de commande optimale. L'objectif principal de notre travail est de développer et simuler grâce au logiciel Matlab/simulink[™] une technique neuronale qui nous permettra d'améliorer les performances du système de commande au sein du filtre actif. Ladite technique est essentiellement basée sur un algorithme d'apprentissage optimal qui sera au centre du système de commande réalisé grâce aux perceptrons multicouches.

2. Matériel et méthodes

2-1. Modélisation de la commande du filtre actif parallèle (FAP)

2-1-1. Principe du FAP

Le filtre actif connecté en parallèle sur le réseau électrique est le plus souvent commandé comme un générateur de courant, son rôle est d'empêcher les courants (harmoniques, réactifs et déséquilibrés) produits par les charges polluantes de circuler à travers l'impédance du réseau en les compensant par des courants de mêmes amplitudes et de phases opposées. Son principe est illustré par le schéma de la *Figure 1.*



Figure 1 : Filtre actif parallèle dans un réseau de distribution

2-1-2. Système de commande dans un FAP

La partie contrôle-commande du FAP assure la génération des signaux à injecter dans le réseau électrique. Ces signaux sont les courants de références en sortie du bloc d'identification. Le principe de cette commande est basé sur la comparaison entre le courant injecte i_{inj} généré par le FAP et le courant de référence i_{ref} , afin d'en déduire les ordres de commande de l'onduleur de tension. En effet, ce dernier comporte généralement des transistors dont il convient de piloter l'ouverture et la fermeture. La structure du système de commande de l'onduleur de tension peut être séparée en deux sous-systèmes ayant des dynamiques différentes :

- L'une dite rapide qui est liée aux courants,
- Et une autre dite lente qui est associée à la tension continue.

On peut de ce fait, synthétiser deux régulateurs, un pour la boucle interne des courants et un autre pour la boucle externe de la tension continue. D'autre part, il est bien connu que la performance de la boucle des courants joue un rôle essentiel dans la performance globale du système; c'est pourquoi une commande ayant une réponse rapide et un bon comportement en état stationnaire s'avère nécessaire.

2-1-3. Modélisation neuronale de la commande du FAP

2-1-3-1. Identification des courants de référence

En prélevant le courant absorbé par une charge non linéaire, sa décomposition en série de Fourier pour chaque phase révèle les deux composantes de *l'Expression (1).*

$$i_c(t) = i_{cf}(t) + i_{ch}(t)$$
 (1)

 $i_{cf}(t)$ étant le courant fondamental et $i_{ch}(t)$ le courant harmonique.

Leurs expressions sont les suivantes :

$$i_{ch}(t) = I_{11}\cos(\omega kt - \alpha) + I_{12}\sin(\omega kt - \alpha)$$
⁽²⁾

$$i_{ch}(t) = \sum_{n=2}^{N} \left\{ I_{n1} \cos\left[n(\omega kt - \alpha)\right] + I_{n2} \sin\left[n(\omega kt - \alpha)\right] \right\}$$
(3)

 ω étant la pulsation fondamentale du réseau, α un déphasage quelconque, I_{11} et I_{12} les amplitudes associés au cosinus et au sinus du fondamental, I_{n1} et I_{n2} les coefficients des termes en cosinus et en sinus du courant harmonique, n est l'ordre des harmoniques générés par la charge non-linéaire.

Le courant de charge peut alors s'écrire sous la forme matricielle (4).

$$i_c(t) = W^T \cdot X(t) \tag{4}$$

avec, W le vecteur des coefficients I_{ij} et X le vecteur des termes en cosinus et en sinus :

$$W^{T}(t) = \begin{bmatrix} I_{11} & I_{12} & I_{21} & I_{22} & \dots & I_{n1} & I_{n2} \end{bmatrix}$$
(5)

$$X(t) = \left[\cos(\omega t - \alpha) \sin(\omega t - \alpha) \ldots \cos(n\omega t - \alpha) \sin(n\omega t - \alpha)\right]$$
(6)

En utilisant la forme simplifiée de l'algorithme de Widrow-Hoff pour l'apprentissage des coefficients I_{ij} , l'identification des harmoniques dans l'espace abc peut se faire directement par un Adaline identique sur chaque phase.

$$W(k+1) = w(k) + \mu . e(k) . X(k)$$
(7)

De cette façon, W sera le vecteur poids de l'Adaline dont les entrées seront les termes du vecteur X (à l'exception d'un terme constant qui correspond à un biais). La *Figure 2* permet d'illustrer l'utilisation de l'Adaline pour l'identification des harmoniques sur la phase a



Figure 2 : Modèle de l'Adaline pour l'identification (phase a)

Le courant fondamental estimé est alors évalué par *l'Expression (8)* dans laquelle α est considéré nul.

$$i_{cf}(t) = W_{a1} \cos \omega t + W_{b1} \sin \omega t \tag{8}$$

Par conséquent, le courant harmonique se déduit de *l'Expression (1)* par *la Relation (9)*

$$i_{ch}(t) = i_c(t) - i_{cf}(t)$$
(9)

Pour la plupart des applications, le paramètre d'apprentissage μ peut être déterminé de façon empirique sans porter préjudice à la rigueur scientifique du travail. Nous pouvons donc ainsi identifier individuellement les harmoniques afin de réaliser une compensation sélective. À ce titre, il suffit de déterminer les amplitudes à partir des poids de l'Adaline correspondant aux composantes cosinus et sinus des harmoniques concernées. Pour une harmonique d'ordre N, son amplitude sera obtenue par *la Relation (10).*

$$I_{cN} = W_{aN}^2 + W_{bN}^2 \text{ (avec } W_{aN} = I_{N1} \text{ et } W_{bN} = I_{N2})$$
 (10)

La mise à jour des poids est effectuée grâce à l'Algorithme d'apprentissage de Widrow-Hoff modifié. Son architecture est constituée d'un additionneur, d'un multiplieur à trois entrées et d'un diviseur.

2-1-3-2. Contrôle des courants avec un PI neuronal

Le principe de la commande est d'estimer grâce aux réseaux de neurones les deux paramètres du régulateur PI (le proportionnel et l'intégral). Pour ce faire, chacun des paramètres est associé à un poids $w_0(k)$. L'erreur de l'apprentissage est donnée par $e = i_{ref} - i_{inj}$ (i_{ref} et i_{inj} représentent respectivement le courant de référence et le courant injecté au réseau). L'algorithme de mise à jour des poids est la règle LMS (Least Mean square). Lorsque le signal injecté arrive à suivre la référence (l'erreur e devient minimale) selon les critères fixés par l'utilisateur, alors l'apprentissage peut être arrêté. L'ADALINE joue ensuite le rôle d'un PI non adaptatif. Si des variations importantes surviennent au niveau du système à commander, l'apprentissage peut reprendre. La *Figure 3* ci-dessous représente le schéma de commande avec un régulateur PI neuronal



Figure 3 : Schéma de commande avec un régulateur PI neuronal

2-1-3-3. Commande de l'onduleur à base des perceptrons multicouches : algorithme d'optimisation

La **Figure** 4 ci-dessous représente l'architecture du neurocontrôleur MLP (Multilayer Perceptron). Il est constitué de 3 couches à savoir : une couche d'entrée composée de 4 neurones, une couche cachée composée de 5 neurones et en fin une couche de sortie composée d'un seul neurone. O_i , O_j et O_m représentent respectivement les valeurs à la sortie des neurones de la couche d'entrée, de la couche cachée et de la couche de sortie. Dans cette architecture, l'information circule de la couche d'entrée vers la couche de sortie uniquement. Un module d'algorithme d'apprentissage lui est associé.



Figure 4 : Architecture du neurocontrôleur MLP

Après l'étape d'indentification, le courant "identifié" est réinjecté dans le réseau grâce au neurocontrôleur via l'onduleur et le filtre de sortie. L'algorithme de rétropropagation du gradient utilisé comme algorithme d'apprentissage assure la mise à jour des poids.

2-2. Méthodologie d'optimisation du filtrage actif : algorithme de rétropropagation

L'optimisation du filtrage actif est principalement centrée sur l'algorithme d'apprentissage. Soit x(t) le vecteur d'entrées du réseau. La fonction de coût J(k) peut s'écrire comme suit :

$$J(k) = \frac{1}{2} \cdot E\left[e^2(k)\right] \tag{11}$$

$$e(k) = y_d(k) - y_{est}(k) = y_d(k) - \sum_{i=1}^{m} \left[X_i(k) - W_i(k) \right]$$
(12)

Le but de l'algorithme d'apprentissage est de minimiser la fonction J en modifiant les poids W_i . La convergence de l'algorithme est atteinte pour une valeur minimale de la fonction de coût J qui représente la surface de l'erreur du réseau. Cette condition optimale est obtenue quand la dérivée de J par rapport aux poids W_i est égale à zéro. Cette dérivée est appelée le gradient de l'erreur surfacique :

$$\frac{\partial J(k)}{\partial W_i} = \nabla_{W_i} J(k) \tag{13}$$

La méthode du gradient simple suppose que les poids varient avec le temps et ses valeurs sont modifiées de manière itérative suivant l'erreur surfacique afin d'atteindre le point minimal de J. Il est intuitif de montrer que la direction de l'adaptation des poids est opposée à celle du vecteur du gradient J dont les éléments sont définis par $\nabla_{W_i} J(k)$ avec i = 1, 2, ..., m. Pour cette méthode, l'adaptation appliquée au poids $W_i(k)$ à l'itération k est définie par :

$$\Delta W_i(k) = -\mu \cdot \nabla_{W_i} J(k) \tag{14}$$

μ étant une constante positive proche de zéro appelée *coefficient d'apprentissage* (choisie entre 0 et 1). Enfin, la mise à jour des poids sera effectuée par :

$$W_{i}(k+1) = W_{i}(k) - \mu \nabla_{W_{i}} J(k)$$
(15)

L'algorithme LMS nous permet d'en déduire *l'Équation* suivante :

$$W_i(k+1) = W_i(k) - \mu [y_d(k) - y_{est}(k)] .x_i(k)$$
(16)

Le vecteur de poids W(k) qui est constitué par les poids s'écrit :

$$W(k) = \left[W_1(k) \ W_2(k) \dots W_m(k) \right]^T$$
(17)

Il converge vers un vecteur optimal $W_{opt}(k)$ et cela en commençant par les valeurs initiales W(0) et en poursuivant précisément une trajectoire bien définie (à l'opposé de la direction du gradient).

2-2-1. Algorithme de rétropropagation

Cet algorithme permet de réaliser un apprentissage du réseau de neurones. On cherche à obtenir du réseau une réponse préétablie comme étant correcte. C'est donc un apprentissage supervisé dont les variables sont définies dans le *Tableau 1.*

Variables	Définition de la variable	Dimension
X	Vecteur d'entrées au réseau	$(m \times 1)$
$W^{(1)}$	Matrice des poids dans la couche cachée	$(m \times n)$
$X^{(1)}$	Vecteur d'entrées des neurones dans la couche cachée	$(n \times 1)$
<i>O</i> ⁽¹⁾	Vecteur de sortie des neurones de la couche cachée	$(n \times 1)$
$\Lambda^{(1)}$	Vecteur de l'erreur de rétropropagation de la couche cachée	$(n \times 1)$
W ⁽²⁾	Matrice des poids de la couche de sortie	$(n \times p)$
X ⁽²⁾	Vecteur d'entrées des neurones dans la couche de sortie	$(p \times 1)$
0 ⁽²⁾	Vecteur de sortie des neurones dans la couche de sortie	$(p \times 1)$
$\Lambda^{(2)}$	Vecteur de l'erreur de rétropropagation de la couche de sortie	$(p \times 1)$

 Tableau 1 : Variables d'implémentation

Nous avons :

$$X^{(1)}(k) = \left[W^{(1)}(k)\right]^{T} \cdot X(k), \ O^{(1)}(k) = f^{(1)}(X^{(1)}(k)), \ X^{(2)}(k) = \left[W^{(2)}(k)\right]^{T} \cdot O^{(1)}(k),$$
$$O^{(2)}(k) = f^{(2)}(X^{(2)}(k)) \text{ et } y(k) = O^{(2)}(k)$$

Tel que $f^{(1)}(.)$ et $f^{(2)}(.)$ sont respectivement les fonctions d'activation de la couche cachée et de la couche de sortie.

Le vecteur de sortie du réseau MLP y(k) peut être calculé selon *l'Équation (18)*:

$$y(k) = f^{(2)}\left(\left[W^{(2)}(k)\right]^T \cdot f^{(1)}\left(\left[W^{(1)}(k)\right]^T \cdot X(k)\right)\right)$$
(18)

La fonction d'activation $f^{(2)}$ de la couche de sortie du RNA étant linéaire ($f^{(2)}$ est une fonction identité), la sortie du RNA peut être réécrite suivant *la Relation (19)*:

$$y(k) = \left[W^{(2)}(k) \right]^{T} \cdot f^{(1)} \left(\left[W^{(1)}(k) \right]^{T} \cdot X(k) \right)$$
(19)

La fonction J à minimiser est définie par *l'Équation (20)*:

$$y(k) = \frac{1}{2} \sum_{i=1}^{m} \left[y_{di}(k) - y_i(k) \right]^2$$
(20)

2-2-2. Rétropropagation des erreurs et mise à jour des poids

Le principe de la rétropropagation consiste à minimiser l'erreur de chaque couche k du réseau de neurones. Une adaptation ΔW^2 des poids est calculée par la **Relation (21)**. $\Lambda^{(2)}$ représente l'erreur de rétropropagation de la couche de sortie :

$$\Delta W^{(2)}(k) = -\gamma O^{(1)}(k) \left[\wedge^{(2)}(k) \right]^{T}$$
(21)

La fonction d'activation de la couche de sortie est linéaire, l'erreur de rétropropagation est donc égale à :

$$\wedge^{(2)}(k) = y(k) - y_{est}(k)$$
(22)

De même pour les poids de la couche cachée, leur mise à jour est faite de la manière suivante :

$$\Delta W^{(1)}(k) = -\gamma . y(k) . X(k) . \left[\wedge^{(2)}(k) \right]^T$$
(23)

où, le vecteur de l'erreur de rétropropagation de la couche cachée $\Lambda^{(1)}$ doit prendre en compte toutes les erreurs des neurones de la couche de sortie tel que (avec i=1,...., n):

$$\wedge_{i}^{(1)}(k) = O^{(1)}(k) \cdot \left(1 - O^{(1)}(k)\right) \cdot \sum_{j=1}^{p} W_{ij}(k) \cdot \wedge_{j}^{(2)}(k)$$
(24)

Le terme $O^{(1)}(k)$. $(1-O^{(1)}(k))$ représente la dérivée de la sortie de la fonction d'activation sigmoïdale dans la couche cachée.

3. Résultats et discussion

3-2. Paramètres de simulations

Le *Tableau 2* nous donne les paramètres électriques des différents éléments utilisés lors des simulations de notre système de dépollution des réseaux électriques par les filtres actifs parallèles dans le Laboratoire Virtuel Matlab/simulink™

Source de tension	Tension éq Phase-Neutre Vs = 200	Tension équilibrées Phase-Neutre Vs = 200 V, Fréquence = 50 Hz		
Charge linéaire	$R_c = 20 \Omega_r I$	$R_c = 20 \Omega$, $L_c = 13 mH$		
Filtre de sortie	$R=3\Omega$ et	R = 3 Ω et L = 7 mH		
Bus continu de l'onduleur	$Cdc = 1000 \mu F,$	$Cdc = 1000 \mu F, V_{dcref} = 300 V$		
	Amplitude	Fréquence (hz)		
Composante fondamentale	100	50		
Harmonique d'ordre 5	20	250		
Harmonique d'ordre 7	100/7	350		

Tableau 2 : Paramètres de simulations

3-2. Résultats de simulations du système sans filtre actif

3-2-1. Cas d'une charge linéaire

Au départ nous considérons un système constitué par le réseau électrique qui est représenté par une source de tension triphasée parfaitement sinusoïdale débitant sur une charge linéaire RL. Le modèle simulink est représenté sur la *Figure 5*.



Figure 5 : Modèle Simulink du réseau alimentant une charge linéaire

Les *Figures 6 et 7* illustrent respectivement la tension du réseau et les courants de charge ainsi que leurs spectres.



Figure 7 : Courant de ligne et son spectre pour une charge linéaire

On remarque que les signaux sont purement sinusoïdaux et les spectres ne présentent aucune composante harmonique (THD = 0.00 %). Les charges linéaires ne sont donc pas génératrices d'harmonique.

3-2-2. Cas d'une charge non-linéaire

307

Ici, considérons un système constitué par le même réseau électrique que précédemment débitant sur une charge non-linéaire comme l'indique le schéma synoptique ci-dessous. Pour mieux apprécier l'impact des harmoniques sur le réseau, nous avons choisi comme charge non-linéaire un PD3 non commandé.



Figure 8 : Modèle Simulink du réseau alimentant une charge non-linéaire

Les *Figures 9 et 10* ci-dessous nous présentent les résultats de simulations :



Figure 9 : Tension du réseau et spectre



Figure 10 : Courant de ligne et spectre pour redresseur triphasé

Nous pouvons lire sur le spectre du courant de ligne une valeur de 31.71 % correspondant au THD global. Le PD3 non commandé représentant la charge non linéaire est donc génératrice d'harmonique. Nous allons dans la section suivante identifier les courants de référence (sur une phase) qui vont être réinjectés au réseau afin de compenser les harmoniques générés.

3-3. Identification des courants de référence phase a

L'identification neuronale effectuée grâce aux réseaux de neurones nous a permis d'élaborer les courants de référence. Ces courants qui seront réinjectés au réseau afin de compenser les harmoniques. La *Figure 7* cidessous nous présente l'allure de ces courants obtenue sur la première phase du réseau.



Figure 11 : Modèle simulink du système global d'identification et Courant de référence de la phase a

3-4. Simulation du réseau compensé

Dans cette section, nous présenterons les résultats obtenus grâce aux systèmes de compensation. Une visualisation du courant en ligne et de son spectre nous permettra de conclure sur la performance des différents systèmes.

3-4-1. Compensation avec un PI neuronal

La *Figure 12* ci-dessous represente le modèle simulink du système global de compensation.



Figure 12 : Modèle simulink du système global de compensation avec un régulateur PI neuronal

Les résultats obtenus sont présentés sur les *Figures 13 et 14*. La *Figure 13* est une supperposition du courant de reference, du courant injecté au réseau (qui est sensé suivre sa reference) et de l'erreur d'estimation qui illustre l'écart entre les deux signaux.



Figure 13 : Courant de référence, courant injecté et erreur

Enfin, dans le but d'analyser l'efficacité du système de compensation, la *Figure 14* nous présente le courant en ligne après filtrage ainsi que son spectre



Figure 14 : Courant de ligne et spectre après filtrage

On constate à partir du spectre de courant que la valeur du THD est passée de 31,71 % à 2,46 %. Ceci nous montre que la commande élaborée permet d'éliminer efficacement les harmoniques rendant ainsi le courant de ligne presque sinusoïdal. Cependant, nous allons démontrer dans la section suivante que cette valeur peut être améliorée grâce à la compensation à base de perceptron multicouche.

3-4-2. Compensation neuronale à base de MLP

Nous présentons à la *Figure 15* le modèle simulink du sytème global de compenstaion neuronale, à base des perceptrons multicouches et de l'implémentation de l'algorithme de rétropropagation du gradient.



Figure 15 : Modèle simulink du système de compensation

La *Figure 16* nous présente le courant de référence et le courant estimé et d'apprécier en plus l'erreur d'estimation entre les deux signaux. Enfin, sur la *Figure 17*, nous pouvons visualiser le courant de ligne et son spectre après filtrage. Ce spectre montre une élimination plus nette des harmoniques de courant.



Figure 16 : Courant de référence, courant injecté et erreur



Figure 17: Courant de ligne et spectre après filtrage

Nous obtenons enfin un courant en ligne compensé et une valeur de THD de 1,85 % qui est nettement meilleur par rapport aux 2,46 % obtenus précédemment.

3-5. Régulation du bus continu

311

Il est nécessaire de maintenir constante la tension côté continu de l'onduleur afin de ne pas dégrader la qualité du filtrage ni dépasser la limite en tension des semi-conducteurs. La source de tension continue qui alimente l'onduleur est en pratique réalisée à l'aide d'un système de stockage capacitif, représenté par un condensateur *(Figure 12).* Afin de contrôler la tension à ses bornes, une boucle régulation est réalisée *(Figure 12).* La *Figure 18* ci-dessous nous montre une évolution de la tension du bus continu, la référence étant de 300 V.



Figure 18 : Tension du bus continu après compensation

3-6. Comparaison des résultats et discussion

Le *Tableau 3* ci-dessous récapitule les différentes valeurs obtenues lors des simulations.

Tableau 3 : <i>Tab</i>	leau comparatif
------------------------	-----------------

	Système non compensé	Commande avec un PI neuronal	Commande avec perceptrons multicouches
Valeur THD global courant de ligne	3 1.71 %	2.46 %	1.85 %
Comparaison à la valeur THD normalisée (IEEE Std 519-1992)	> 5 %	< 5 %	< 5 %

Nous remarquons que tous les systèmes de compensation simulés nous ont permis de compenser les harmoniques présents sur le réseau. La valeur du THD global du courant de ligne initialement de 31.71 % a été ramenée à 2.46 % avec puis à 1.85 % grâce à la commande avec perceptrons multicouches. Le standard IEEE 519-1992 fixant le taux maximal à 5 % nous permet de conclure que les valeurs obtenues après compensation sont normalisées. Par ailleurs, la méthode de compensation neuronale à base de perceptrons multicouches dotée d'un algorithme d'optimisation que nous avons développé offre de meilleurs résultats pour la compensation harmonique.

4. Conclusion

Notre objectif dans le cadre de ce travail de recherche était d'élaborer une commande intelligente optimisant le filtrage actif afin de résoudre le problème de la pollution harmonique des réseaux électriques de distribution. Les résultats présentés ci-dessus nous montrent que la totalité de nos objectifs ont été atteint. En effet, la simulation d'un redresseur PD3 non-commandé alimenté par une source alternative et purement sinusoïdale nous a permis d'évaluer l'impact de ce dernier sur le réseau, le THD du système a été évalué à 31.71 %. Dans le souci de compenser les harmoniques présents, nous avons modélisé et simulé deux méthodes de compensation. La première qui est celle d'un régulateur PI neuronal nous a permis de ramener le THD du courant en ligne à 2.76 %. Puis cette valeur a été améliorée grâce à la compensation à base des perceptrons multicouches et nous avons finalement obtenu un THD global du courant de ligne de 1.85 %.

Références

- [1] S. BASAK, C CHAKRABORTY, "A New Optimal Current Control Technique for Dual Stator Winding Induction Generator", IEEE journal of emerging and selected topics in power electronics, Vol. 5, N° 2, (June 2017)
- [2] D. OULD ABDESLAM, P. WIRA, J. MERCKLÉ, Y.-A. CHAPUIS, D. FLIELLER, "Stratégie neuromimétique d'identification et de commande d'un filtre actif parallèle", Revue des Systèmes, Série Revue Internationale de Génie Electrique (RS-RIGE), Vol. 9, N° 1, (2006) 35 - 64 p.
- [3] A. T. BOUM, G.B KEUBENG, L. BITJOKA, "Sliding mode control of a three-phase parallel active filter based on a two-level voltage converter", *Systems Science & Control Engineering*, Vol. 5, (2017)
- [4] Y. FANG, J. FEI, K. MA, "Model reference adaptive sliding mode control using RBF neural network for active power filter", *Electrical Power and Energy Systems*, 73 (2015) 249 258
- [5] M. QASIM, P. KANJIYA, V. KHADKIKAR, "Artificial-Neural-Network-Based Phase-Locking Scheme for Active Power Filters", *IEEE transactions on industrial electronics*, Vol. 61, N° 8 (August 2014)
- [6] Z. YANG, J. SUN, S. LI, M. HUANG, X. ZHA, Y. TANG, "An Adaptive Carrier Frequency Optimization Method for Harmonic Energy Unbalance Minimization in a Cascaded H-Bridge-Based Active Power Filter", *IEEE transactions on power electronics*, Vol. 33, N° 2 (February 2018)
- [7] Z. SHU, M. LIU, L. ZHAO, S. SONG, Q. ZHOU, X. HE, "Predictive Harmonic Control and Its Optimal Digital Implementation for MMC-Based Active Power Filter", *IEEE transactions on industrial electronics*, Vol. 63, N° 8 (August 2016)
- [8] S. N. ESSIANE, S. P. NGOFFE, A. M. IMANO, L.N NNEME, "proposition d'un schéma de contrôle d'un filtre hybride parallèle", *Sciences Technologies et Development*, Vol. 14, (Novembre 2013) 9 - 19 p.
- [9] V. B. CHAU, V. O CONGPHUONG, "Integrated Mathematical Model and Control Design for Hybrid Active Power Filter", *International Journal of Applied Engineering Research*, ISSN 0973-4562 Vol. 12, N° 12 (2017) 3015 - 3022 p.
- [10] D. ARANZAZU, MARTINA, R. S. HERRERA, J. R. VAZQUEZ, P. CROLLA GRAEME M. BURT, "Unbalance and harmonic distortion assessment in an experimental distribution network", *Electrical Power and Energy Systems*, 127 (2015) 271 - 279
- [11] B. MANGAIYARKARASI, P. M. BALASUBRAMANIAM, "Implementation of Artificial Neural Network Controlled Shunt Active Power Filter for Current Harmonics Compensation", *International Journal of* Advanced Research in Computer and Communication Engineering, Vol. 4, Issue 5, (May 2015)
- [12] M. MONA, A. AHMED, N. MAGED, F. AHMED, E. ESSAM, "Harmonic Current Extraction of Shunt Active Power Filter Based on Prediction Current Technique - Hysteresis PWM", 3rd International Conference on ADVANCED CONTROL CIRCUITS AND SYSTEMS, 30 Nov. - 03 Dec. 2013, Luxor, Egypt
- [13] A. ADEL, A. ELGAMMAL, F. MOHAMMED EL-NAGGAR, "MOPSO-based optimal control of shunt active power filter using a variable structure fuzzy logic sliding mode controller for hybrid (FC-PV-Wind-Battery) energy utilization scheme", *IET Renewable Power Generation*, (February 2017)
- [14] S. R. DZONDÉ NAOUSSI, N. K. NGUYEN, C-H. KOM, H. BERVILLER, J-P. BLONDÉ, M. KOM, AND F. BRAUN, "FPGA resources reduction by a multiplexing technique applied on ANN-based harmonics extraction algorithms", *Journal of Energy and Power Engineering*, USA, 6 (2012) 469 - 477
- [15] G. AMAR, L. CHERIF, B. DOUADI, H. LINDA, M. ALI, "FPGA based on-line Artificial Neural Network Selective Harmonic Elimination PWM technique", *Electrical Power and Energy Systems*, 68 (2015) 33 - 43
- [16] M. QASIM, P. KANJIYA, V. KHADKIKAR, "Artificial-Neural-Network-Based Phase-Locking Scheme for Active Power Filters", *IEEE transactions on industrial electronics*, Vol. 61, N° 8 (August 2014)