

Exploitation des réseaux de neurones de type feedforward pour améliorer la performance de la prédistorsion et application aux signaux FBMC-OQAM

Rakotonirina H.B.¹, Randriamitantsoa P.A.², Andriamanalina A.N.³

Laboratoire de Recherche en Télécommunication, Automatique, Signal et Images (LR-TASI)

Ecole Doctorale en Science et Technique de l'Ingénierie et de l'Innovation (ED – STII)

¹dao.rakotonirina@gmail.com,²rpauguste@gmail.com,³andonirinabe@gmail.com

Résumé

Dans cet article, nous avons proposé une nouvelle technique de linéarisation de l'amplificateur de puissance basée sur la prédistorsion à base de réseau de neurones de type feedforward. D'après la propriété d'approximation universelle des réseaux de neurones, la fonction de prédistorsion peut être modélisée à l'aide d'un réseau de type feedforward. Cet article présente la performance de cette nouvelle technique dans un système de transmission utilisant la modulation FBMC-OQAM (Filter Bank MultiCarrier- Offset Quadrature Amplitude Modulation).

Mots clés : Amplificateur de puissance, FBMC-OQAM, prédistorsion, réseau de neurones, non-linéarité, PAPR.

Abstract

In this article, we proposed a new linearization technique of the power amplifier based on predistortion with feedforward neural network. According to the universal approximation of the neural network, a feedforward neural network

allow to model the predistortion function. This article presents the performance of this new technique in a transmission system using FBMC-OQAM modulation (Filter Bank MultiCarrier-Offset Quadrature Amplitude Modulation).

Keywords : Power Amplifier, FBMC-OQAM, predistortion, neural network, non-linearity, PAPR

1. Introduction

Les systèmes de télécommunication actuels et futurs vont utiliser des modulations multiporteuses mais non plus des modulations monoporteuses dans le but d'augmenter le débit et de diminuer les erreurs de transmission. La plus célèbre des modulations multiporteuses est l'OFDM (Orthogonal Frequency Division Multiplexing), cependant, à cause de ses inconvénients, elle va laisser sa place à d'autre type de modulations multiporteuses comme la modulation FBMC-OQAM. Et les systèmes de télécommunication futurs sont presque basés sur ce type de modulation. Malgré les avantages offerts par la modulation FBMC-OQAM, son

inconvéniént majeur est la forte variation d'amplitude du signal modulé qui crée un problème au niveau de l'amplificateur de puissance. Et nos travaux consistent à dénouer ce problème.

2. Amplificateur de puissance face aux signaux FBMC-OQAM

2.1 Caractéristiques des signaux multiporteuses

Les signaux multiporteuses comme les signaux OFDM et les signaux FBMC-OQAM sont caractérisés par une forte variation d'amplitude.

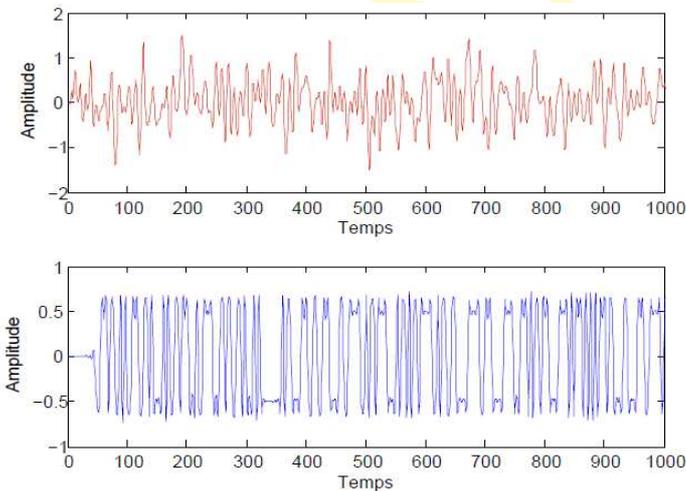


Figure 1 : Signal multiporteuses (en haut) et signal monoporteuse (en bas)

Pour mesurer la variation d'amplitude du signal, on utilise le PAPR (Peak to Average Power Ratio). En effet, lorsque le PAPR est élevé le signal présente de forte variation d'amplitude et dans le cas contraire, le PAPR est faible.

L'équation 01 nous donne l'expression générale du PAPR. Ce paramètre est défini comme le rapport entre la puissance maximale (P_{max}) et la puissance moyenne (P_{moy}) du signal sur un intervalle de temps T [1][2][3] :

$$PAPR = \frac{P_{max}}{P_{moy}} = \frac{\max_{t \in [0, T]} |S(t)|^2}{\frac{1}{T} \int_0^T |S(t)|^2 dt} \quad (01)$$

Où dans notre cas $S(t)$ est un signal FBMC-OQAM.

2.2 Effets de l'amplification non-linéaire des signaux FBMC-OQAM

La non-linéarité d'un amplificateur de puissance a pour impact de déformer le signal FBMC-OQAM qui le traverse. En effet, on peut voir des distorsions qui se traduisent par une déformation de la constellation causant des erreurs de transmission (figure 3) et une remontée spectrale qui peut créer des interférences (figure 2).

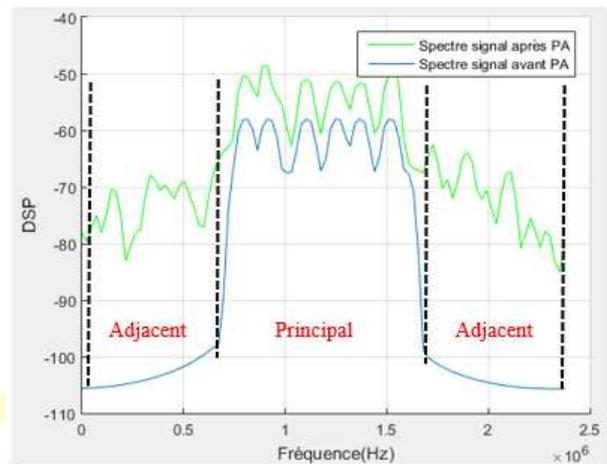


Figure 2: Remontée des lobes secondaires

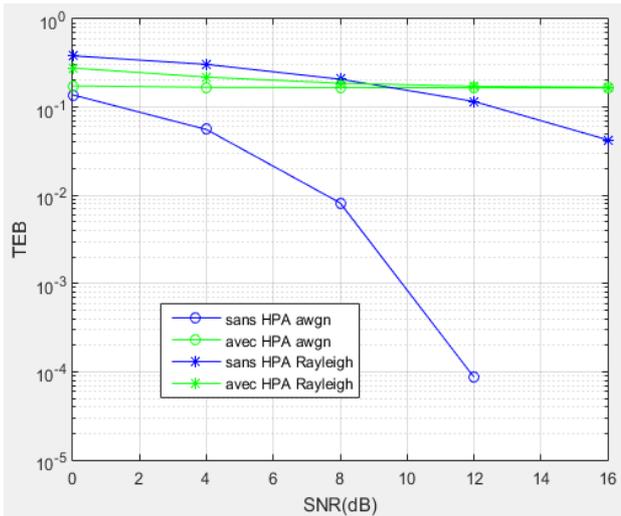


Figure 3 : Comparaison du TEB avec amplification et du TEB sans amplification

La figure 3 nous montre le TEB à la réception d'un signal FBMC-OQAM avec amplification (les courbes en vert) et sans amplification (les courbes en bleu). On constate d'après cette figure que l'amplification non-linéaire dégrade le TEB du signal FBMC-OQAM. Cela vient du fait que la constellation du signal est déformée en traversant l'amplificateur de puissance.

3. Classification des techniques de réduction de la non-linéarité de l'amplificateur de puissance

Les techniques de réduction de la non-linéarité de l'amplificateur se situent soit du côté de l'émetteur, soit du côté du récepteur ou soit réparties entre l'émetteur et le récepteur. Dans cet article, on s'intéresse aux techniques situées à l'émission. Elles se divisent en deux grandes familles :

- La première technique consiste à traiter les signaux à l'entrée de l'amplificateur afin de limiter les effets de la non-

linéarité de ce dispositif. Ce traitement consiste à réduire le PAPR de ces signaux.

- La deuxième technique vise directement à inverser la caractéristique de transfert de l'amplificateur afin de le linéariser. On appelle ces techniques : « techniques de linéarisations ».

Dans la suite, on s'intéresse aux techniques de linéarisation.

Il y a plusieurs variétés de techniques de linéarisation mais la plus performante d'entre elles est la technique de prédistorsion numérique (DPD ou Digital Predistorsion). Elle consiste à compenser la non-linéarité de l'amplificateur en rajoutant à l'entrée de celui-ci un bloc présentant une non-linéarité inverse, de façon que la juxtaposition des deux blocs non-linéaires donne une fonction de transfert linéaire (voir la figure 4).

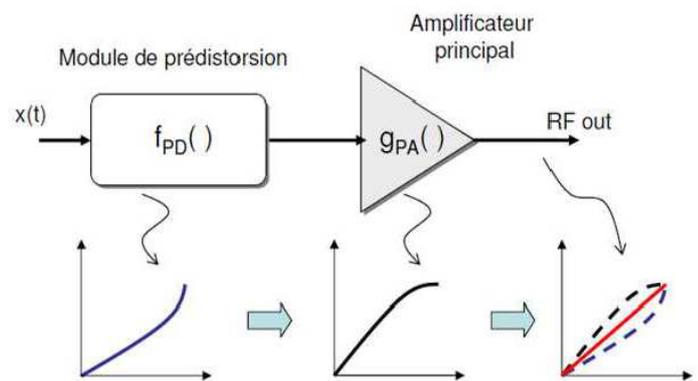


Figure 4: Principe de la technique de prédistorsion

La prédistorsion numérique se divise en deux catégories [2] :

- Prédistorion par tables de correspondance LUT (Look-up table)
- Prédistorion par modèles mathématiques

Dans cet article, nous nous focaliserons sur la prédistorion par modèle mathématique.

4. Prédistorion par modèle mathématique

Cette technique s'appuie sur la modélisation mathématique du système (bloc de prédistorion) utilisé pour déterminer la caractéristique de transfert inverse de l'amplificateur. Dans cette approche, la fonction de prédistorion est implémentée en utilisant des modèles mathématiques. Les modèles les plus utilisés sont : le modèle polynomial et les réseaux de neurones.

Le calcul de la fonction de prédistorion peut se faire de deux manières pour la prédistorion par modèles mathématiques :

- Méthode directe

Le principe de cette technique est de minimiser l'erreur entre les données d'entrée du bloc de prédistorion et les données de sortie de l'amplificateur. Une fois le critère de minimisation rempli, on met à jour directement la fonction de prédistorion.

- Méthode indirecte

Dans cette nouvelle architecture, l'idée est de ne plus boucler le système entre l'entrée du bloc de prédistorion et la sortie de l'amplificateur mais entre l'entrée de l'amplificateur et sa sortie comme l'illustre la figure 5.

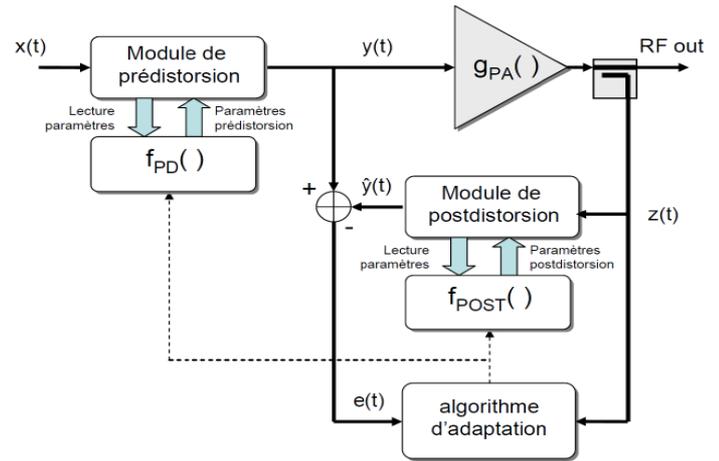


Figure 5 : Principe de l'adaptation indirecte

On parle de méthode indirecte car on ne met plus à jour directement la fonction de prédistorion mais on calcule une fonction f_{POST} appelée fonction de post-distorsion qui n'est autre que la fonction de prédistorion f_{PD} lorsque l'erreur entre y et \tilde{y} est nulle (voir la figure 5).

4.1 Prédistorion par modèle polynomial

Le modèle polynomial est apparu comme une approche assez efficace pour linéariser les amplificateurs. On doit d'abord identifier les coefficients de ce modèle. Pour cela, la méthode d'identification par apprentissage indirect sera mise en œuvre (voir la figure 5). Elle consiste à identifier une fonction de « post-distorsion » f_{POST} à partir des signaux d'entrée et de sortie de l'amplificateur (figure 6). La fonction f_{POST} est déduite par minimisation de l'erreur moyenne $\|x - y_{post}\|^2$ où x est le signal à l'entrée de l'amplificateur et y_{post} le signal à la sortie de la fonction de post-distorsion. Dès que le critère de minimisation est rempli, la fonction estimée de post-distorsion est recopiée dans le module de prédistorion c'est-à-dire $f_{PD} = f_{POST}$.

Voici les étapes à suivre pour la réalisation de la prédistorsion par modèle polynomial :

Etape 1 : Normalisation de la sortie de l'amplificateur de puissance par le gain linéaire G de ce dispositif pour obtenir les échantillons $y_{norm}(n)$ d'expression:

$$y_{norm}(n) = \frac{1}{G} \cdot y(n) \quad (02)$$

Etape 2 : Recherche du polynôme de post-distorsion défini comme suit :

$$y_{post}(n) = f_{POST}(y_{norm}(n)) \quad (03)$$

Cette fonction f_{POST} sera modélisée mathématiquement à l'aide d'un modèle polynomial selon la relation 04.

$$y_{post}(n) = \sum_{k=1}^K a_k y_{norm}(n) |y_{norm}(n)|^{k-1} \quad (04)$$

Où a_k : les coefficients du polynôme, notons qu'on doit les rechercher

K : est l'ordre de la non-linéarité de la fonction de prédistorsion

Sous forme matricielle, l'équation 04 devient :

$$y_{post} = H \cdot a \quad (05)$$

Où

$$y_{post} = [y_{post}(0) \ y_{post}(1) \ \dots \ y_{post}(N-1)]^T$$

avec N le nombre de symbole.

$a = [a_1 \ a_2 \ \dots \ a_K]^T$ le vecteur des coefficients du polynôme de post-distorsion

$$H = [H_1 \ H_2 \ \dots \ H_K]^T$$

Avec $H_k = [h_k(0) \ h_k(1) \ \dots \ h_k(N-1)]^T$ et

$$h_k(n) = \frac{y(n)}{G} \cdot \left| \frac{y(n)}{G} \right|^{k-1}$$

En regardant la figure 6, l'expression de l'erreur de prédistorsion est donnée par l'équation 06.

$$e = x - y_{post} \quad (06)$$

En utilisant les équations 06 et 05, on peut trouver l'expression de l'erreur de prédistorsion moyenne donnée par l'équation 07 :

$$\|x - y_{post}\|^2 = \|x - H \cdot a\|^2 \quad (07)$$

$$\|x - y_{post}\|^2 = (x - Ha)^T (x - Ha) \quad (08)$$

$$\|x - y_{post}\|^2 = x^T x - a^T H^T x - x^T H a + a^T H^T H a \quad (09)$$

Notre objectif c'est de retrouver les coefficients a_k du polynôme de post-distorsion qui minimisent l'erreur moyenne définie par la relation 09, pour cela il faut que sa dérivée par rapport à a soit nulle, on a alors :

$$\frac{d}{da} \|x - Ha\|^2 = 0 \quad - H^T x - H x^T + 2H^T H a \quad (10)$$

$$\frac{d}{da} \|x - Ha\|^2 = -2H^T x + 2H^T H a \quad (11)$$

$$\frac{d}{da} \|x - Ha\|^2 = 0 \leftrightarrow -2H^T x + 2H^T H a = 0 \quad (12)$$

D'où

$$2H^T H a = 2H^T x \quad (13)$$

$$a = (H^T H)^{-1} H^T x \quad (14)$$

Comme les échantillons y sont des nombres complexes, H est une matrice complexe donc la transposée devient hermitien d'où

$$a = (H^H H)^{-1} H^H x \quad (15)$$

Etape 3 : L'étape 2 nous donne l'expression du polynôme de post-distorsion f_{POST} (équation 05) où a est défini par l'équation 15). La dernière

étape consiste à copier ce dernier dans le bloc de prédistorsion c'est-à-dire $f_{PD} = f_{POST}$.

La figure 6 nous résume le principe de cette technique de prédistorsion par modèle polynomial.

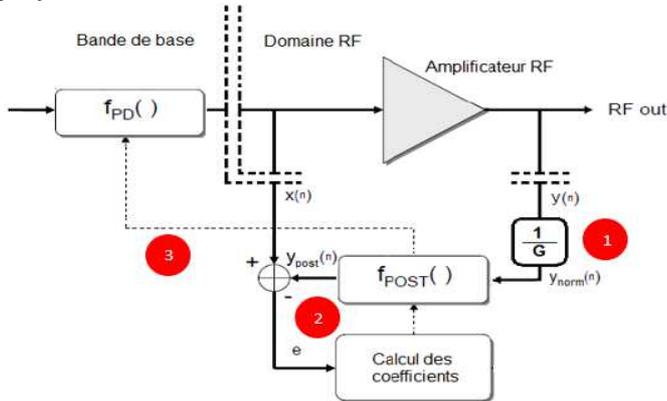


Figure 6: Prédistorsion à base de modèle polynomial avec apprentissage indirect

4.2 Prédistorsion à base de réseau de neurones

4.2.1 Neurone formel (neurone artificiel)

La figure 7 nous montre le schéma d'un neurone formel ou neurone artificiel

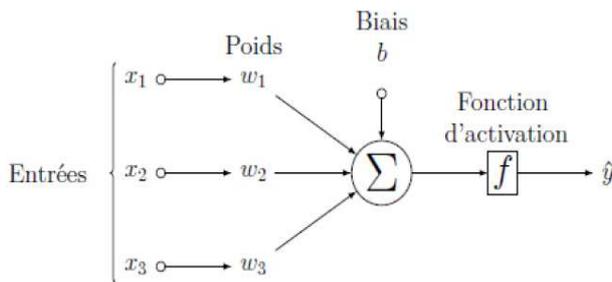


Figure 7: Neurone artificiel

Le neurone formel est une modélisation mathématique des principes de fonctionnement du neurone biologique. Il reçoit des variables d'entrées en provenance des autres neurones. A chacune des entrées est associé un poids w_i représentatif de la force de connexion. Les informations ainsi recueillies sont traitées par

une fonction dite d'activation ou de transfert pour donner la sortie du neurone [4][5].

4.2.2 Réseau de neurones de type feedforward

Un réseau de neurone artificiel est l'interconnexion de plusieurs neurones formels. Un réseau de type feedforward est un réseau dont tous les neurones d'une couche sont reliés à tous les neurones de la couche suivante.

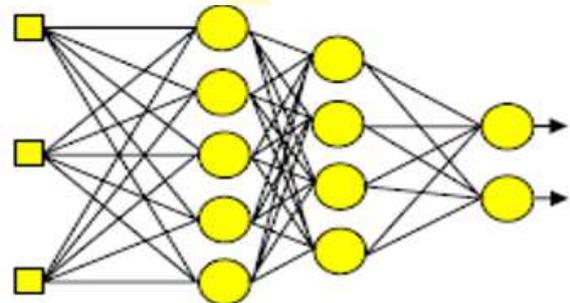


Figure 8: Réseau de neurones de type feedforward

4.2.3 Propriété d'approximation universelle des réseaux de neurones

Cette propriété s'énonce comme suit : « pour toute fonction, il existe au moins un réseau de neurones non bouclé, possédant une couche de neurones cachés et un neurone de sortie linéaire, qui réalise une approximation de cette fonction et de ses dérivées successives »[6]. Donc les réseaux de neurones non bouclés peuvent être tout à fait appropriés pour modéliser la fonction de prédistorsion désirée en vue de linéariser l'amplificateur. Parmi les diverses architectures de réseaux non bouclés, nous allons utiliser un réseau de neurones de type feedforward.

4.2.4 Principe de la prédistorsion à base de réseau de neurones

On peut déduire de la propriété d'« approximation universelle » des réseaux de neurones que la fonction de prédistorsion f_{PD} utilisée pour inverser la caractéristique de transfert de l'amplificateur peut être approximée à l'aide d'un réseau de neurones non bouclé de type feedforward. Pour atteindre ce but, on doit entraîner ce réseau. On va donc utiliser un algorithme d'apprentissage supervisé appelé algorithme de rétro-propagation. Voici alors les étapes à suivre pour la réalisation de la prédistorsion à base de réseau de neurones (Voir aussi la figure 9).

Etape 1 : Initialisation des poids synaptiques du réseau de type feedforward

Etape 2 :

Introduction d'une base d'apprentissage. En effet, le réseau va recevoir à son entrée les données de sortie de l'amplificateur de puissance.

Etape 3 : Le réseau de neurones va estimer les données de sortie qui correspondent aux données d'entrées (les données de sortie de l'amplificateur)

Etape 4 : Comparaison entre les sorties estimées par le réseau de neurones et les sorties désirées qui sont les données d'entrée de l'amplificateur. L'erreur entre ces valeurs est définie par l'équation 16. Souvent on associe à cette erreur une fonction coût J donnée par l'équation 17.

$$e = y_{des} - y_{est} \quad (16)$$

Où

y_{des} : les sorties désirées

y_{est} : les sorties estimées par le réseau de neurones

$$J = \frac{1}{2} \sum (e)^2 \quad (17)$$

Etape 5 : La mise à jour des poids synaptiques du réseau de neurones en utilisant l'équation 18.

$$W_{nouvelle} = W_{ancienne} - \Delta W \quad (18)$$

Où

$W_{ancienne}$: ancienne valeur du poids synaptique

$W_{nouvelle}$: nouvelle valeur du poids synaptique

ΔW : Valeur de correction qui dépend de l'algorithme d'optimisation utilisé pour minimiser la fonction coût J .

Etape 6 : On copie le réseau entraîné dans le bloc de prédistorsion.

La figure 9 résume le principe de la technique de prédistorsion à base de réseau de neurones

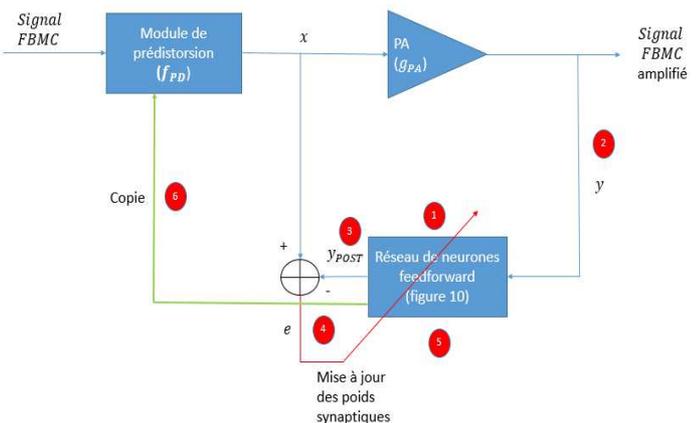


Figure 9: Principe de la prédistorsion à base de réseau de neurones

4.2.5 Caractéristiques du réseau de neurones de type feedforward proposé

Dans cet article, nous sommes dans un contexte de transmission radio-terrestre. C'est pour cette raison que le modèle d'amplificateur utilisé est le modèle de Rapp. Par conséquent, les distorsions causées par ce modèle affectent uniquement l'amplitude du signal amplifié. Donc dans notre cas, le réseau de neurones feedforward utilisé n'a qu'une seule entrée et une seule sortie. La précision de la fonction de prédistorsion dépend des caractéristiques du réseau de neurones utilisé. Dans notre cas, le réseau feedforward est composé de trois couches :

- Une couche d'entrée composée d'un seul neurone. En effet le réseau de neurones utilisé n'a qu'une seule entrée donc un neurone dans la couche d'entrée est logique.
- Une couche cachée de dix neurones ayant une fonction d'activation tangente hyperbolique. En effet, cette fonction d'activation nous permet d'initialiser aléatoirement les poids synaptiques du réseau lors de l'apprentissage, ce qui augmente la vitesse de convergence de l'algorithme d'apprentissage utilisé.
- Une couche de sortie constituée d'un seul neurone dont la fonction d'activation est linéaire.

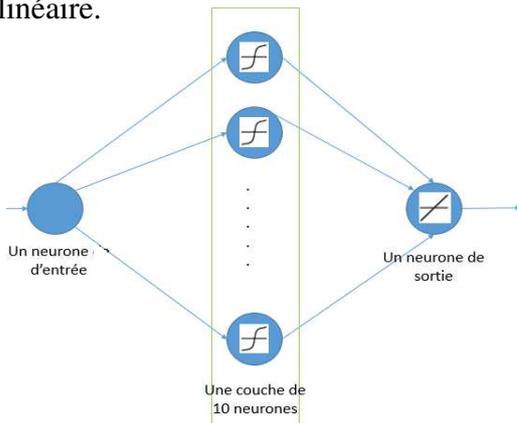


Figure 10: L'architecture du réseau de neurones Feedforward utilisé

On déduit de cette architecture la modélisation mathématique de la fonction de prédistorsion f_{PD} . Elle a pour expression :

$$f_{PD}(x) = \sum_{i=1}^{10} [w_i^{cs} [g(w_i^{ec}x + b_i^c)]] + b_s \quad (19)$$

Où

w_i^{cs} est le poids synaptique entre le $i^{\text{ème}}$ neurone de la couche cachée et le neurone de la couche de sortie,

w_i^{ec} est le poids synaptique entre le neurone de la couche d'entrée et le $i^{\text{ème}}$ neurone de la couche cachée,

b_i^c est le biais du $i^{\text{ème}}$ neurone de la couche cachée,

b_s est le biais du neurone de sortie,

x est le signal d'entrée du bloc de prédistorsion, g est la fonction d'activation des neurones de la couche cachée, dans notre cas c'est une fonction tangente hyperbolique définie par $g(n) =$

$$\frac{e^n - e^{-n}}{e^n + e^{-n}}$$

5. Performance de la prédistorsion à base de réseau de neurones des signaux FBMC-OQAM

5.1 Précision de la fonction de prédistorsion

Nous allons comparer l'allure de la fonction de prédistorsion modélisée à partir du réseau de neurones de type feedforward (équation 19) et

celle modélisée à partir du modèle polynômial (ce modèle est décrit par les équations 05 et 15).

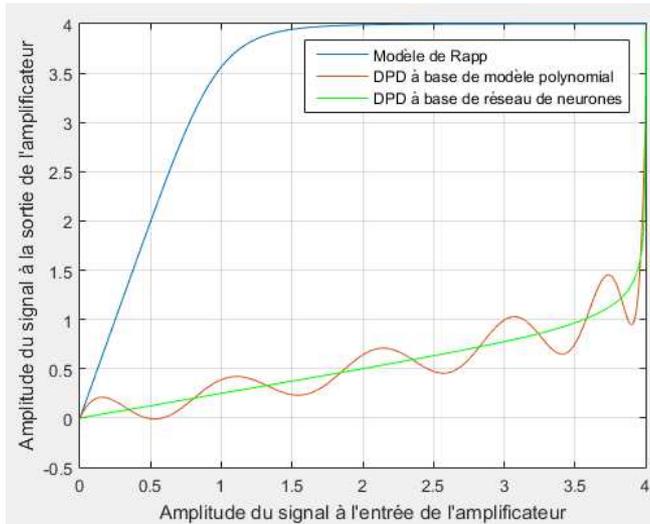


Figure 11 : Comparaison de l'allure des fonctions de prédistorsion obtenues à partir des deux méthodes de prédistorsion

On déduit de cette figure que la fonction de prédistorsion obtenue par l'utilisation du réseau de neurones est plus précise par rapport à celle obtenue par le modèle polynomial. En effet, le réseau de neurones est un approximateur universel donc c'est évident qu'il donne un résultat plus précis par rapport au modèle polynômial. On peut alors conclure que la prédistorsion à base de réseau de neurones est plus performante.

5.2 Allure du spectre d'un signal après prédistorsion

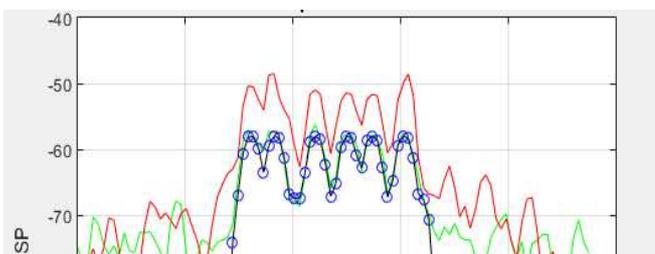
Dans cette partie, on va comparer le spectre d'un signal FBMC-OQAM après prédistorsion numérique à base de réseau de neurones avec celui obtenu après prédistorsion numérique à base de modèle polynomial.

Figure 12 : Spectre du signal FBMC-OQAM obtenu à partir des techniques de prédistorsion numérique

On constate d'après cette figure que les techniques de prédistorsion numérique permettent de diminuer les remontées spectrales causées par la non-linéarité de l'amplificateur. On en déduit aussi que la diminution de la remontée spectrale par la prédistorsion à base de réseau de neurones est plus importante par rapport à celle obtenue après prédistorsion à base de modèle polynomial. Par conséquent, cette dernière peut encore causer des interférences dans les canaux voisins.

On constate aussi que le spectre du signal FBMC-OQAM obtenu après prédistorsion à base de réseau de neurones se superpose avec celui du signal original sans distorsion. Cette performance est due à la précision de la fonction de prédistorsion obtenue à partir du réseau de neurones.

5.3 TEB (Taux d'Erreur Binaire) du signal FBMC-OQAM après prédistorsion



Maintenant, on va comparer le TEB du signal FBMC-OQAM après prédistorsion numérique à base de réseau de neurones avec celui obtenu après prédistorsion numérique à base de modèle polynomial. On utilise toujours le canal AWGN et le canal de Rayleigh.

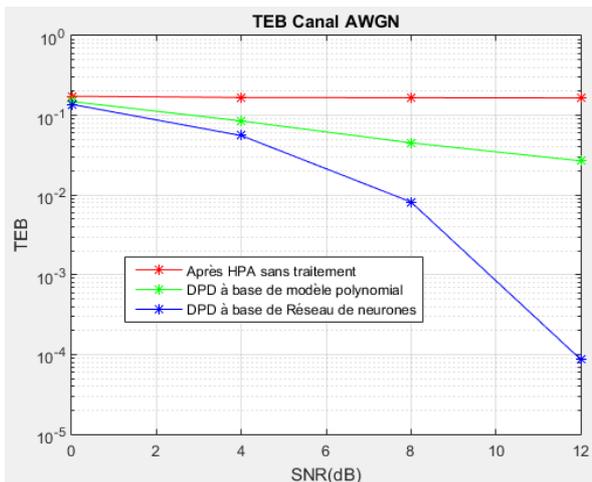


Figure 13 : TEB après prédistorsion numérique à travers un canal AWGN

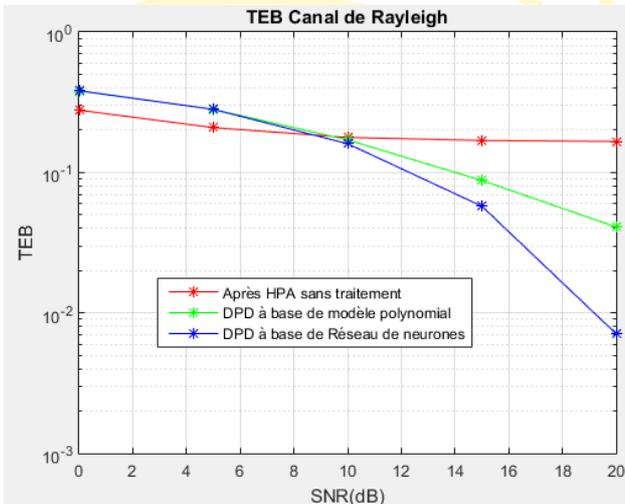


Figure 14 : TEB après prédistorsion numérique à travers un canal de Rayleigh

On déduit de ces deux figures que la prédistorsion à base de réseau de neurones ne dégrade pas le TEB par rapport à la prédistorsion à base de modèle polynomial. C'est aussi la précision de la fonction de prédistorsion obtenue

à partir du réseau de neurones qui explique cette performance.

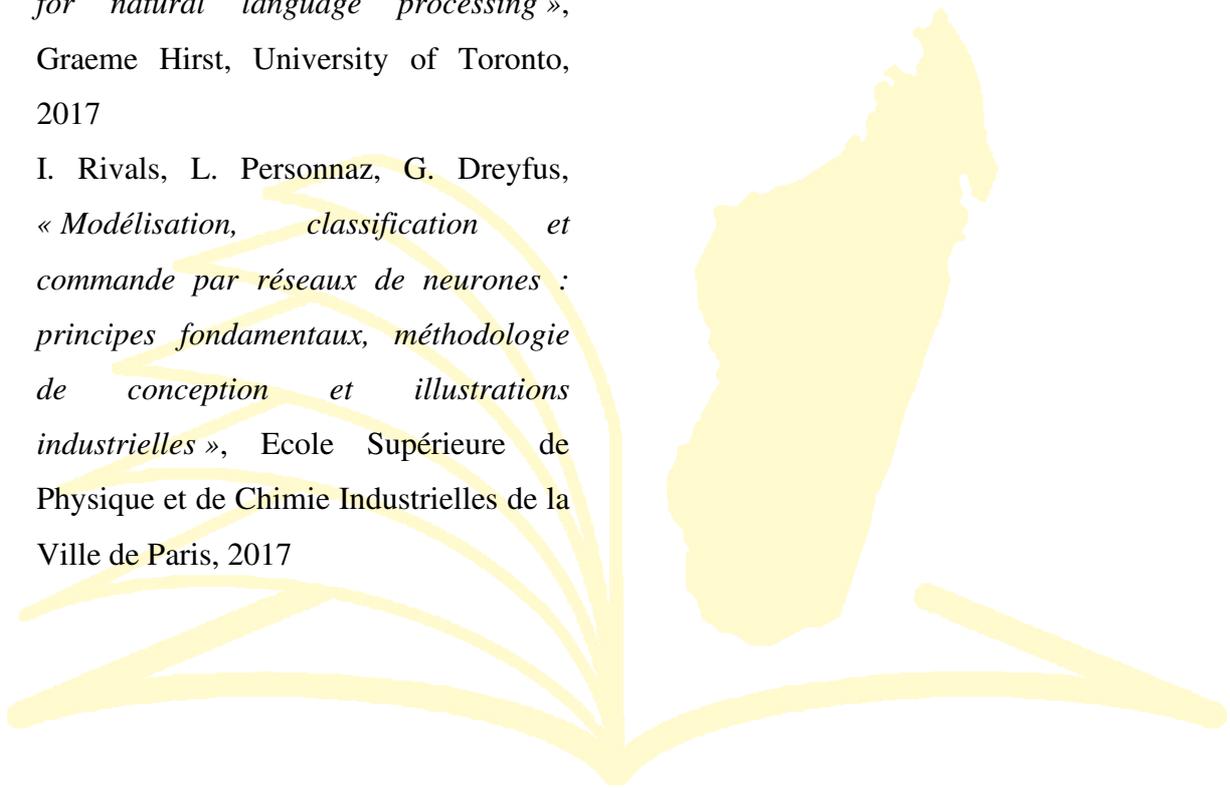
6. Conclusion

Pour augmenter le débit et diminuer les erreurs de transmission, l'utilisation d'une modulation multiporteuses comme la modulation FBMC-OQAM est indispensable. Cependant, ces signaux créent des énormes problèmes au niveau de l'amplificateur qui se traduisent par l'augmentation du taux d'erreurs et par des interférences. Afin de résoudre ce problème, nous avons proposé une prédistorsion à base de réseau de neurones de type feedforward. Les résultats précédents, nous montre que cette technique permet d'éviter les interférences avec les canaux voisins et permet aussi de diminuer le TEB à la réception. En outre, elle est aussi plus performante que la prédistorsion à base de modèle polynomial. Donc cette nouvelle technique de linéarisation de l'amplificateur est très intéressante.

7. Références

- [1] H. Bogucka, A. Kliks, P. Kryszkiewicz, « *Advanced Multicarrier Technologies for Future Radio Communication* », Wiley, 2017
- [2] M. Ghannouchi, O. Hammi et M. Helaoui, « *Behavioral modeling and predistortion of wideband wireless transmitters* », Wiley, 2015

- [3] W. Chen, K. Rawat, M. Ghannouchi, « *Multiband RF Circuits and Techniques for Wireless Transmitters* », Springer, 2016
- [4] S. Shanmuganathan, S. Samarasinghe, « *Artificial Neural Network Modelling* », Springer, 2016
- [5] Y. Goldberg, « *neural network methods for natural language processing* », Graeme Hirst, University of Toronto, 2017
- [6] I. Rivals, L. Personnaz, G. Dreyfus, « *Modélisation, classification et commande par réseaux de neurones : principes fondamentaux, méthodologie de conception et illustrations industrielles* », Ecole Supérieure de Physique et de Chimie Industrielles de la Ville de Paris, 2017



MADA-ETI