

الجمهورية الجزائرية الديمقراطية الشعبية
REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
وزارة التعليم العالي و البحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
جامعة أبي بكر بلقايد – تلمسان
Université Aboubakr Belkaïd – Tlemcen –
Faculté de TECHNOLOGIE



MEMOIRE

Présenté pour l'obtention du **diplôme** de **MASTER**

En : Télécommunications

Spécialité : Réseaux et Télécommunications

Par : ALI DAHMANE Houda

Sujet

**Prédistortion numérique à base de l'intelligence artificielle
Pour les amplificateurs avec effets mémoire dans les réseaux
de télécommunications**

Soutenu publiquement, le 13/06/2024, devant le jury composé de :

M MERIAH S.M	PROF	Université de Tlemcen	Président
M DERRAZ F	MCA	Université de Tlemcen	Examineur
M BENDIMERAD F.T	PROF	Université de Tlemcen	Encadrant
Mme BENOSMAN M.M	Doctorante	Université de Tlemcen	Co-Encadrante

Année universitaire : 2023/2024

الجمهورية الجزائرية الديمقراطية الشعبية
REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
وزارة التعليم العالي و البحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
جامعة أبي بكر بلقايد – تلمسان
Université Aboubakr Belkaïd – Tlemcen –
Faculté de TECHNOLOGIE



MEMOIRE

Présenté pour l'obtention du **diplôme** de **MASTER**

En : Télécommunications

Spécialité : Réseaux et Télécommunications

Par : ALI DAHMANE Houda

Sujet

**Prédistortion numérique à base de l'intelligence artificielle
Pour les amplificateurs avec effets mémoire dans les réseaux
de télécommunications**

Soutenu publiquement, le 13/06/2024, devant le jury composé de :

M MERIAH S.M	PROF	Université de Tlemcen	Président
M DERRAZ F	MCA	Université de Tlemcen	Examineur
M BENDIMERAD F.T	PROF	Université de Tlemcen	Encadrant
Mme BENOSMAN M.M	Doctorante	Université de Tlemcen	Co-Encadrante

Année universitaire : 2023/2024

DEDICACES

À ma mère, MIRAOUI Hafida, qui m'a toujours soutenue et encouragée dans mes études. Sa bienveillance et son amour inconditionnel ont été ma source d'inspiration.

À mon père, Moussa, dont la sagesse et la persévérance m'ont guidée tout au long de ce parcours académique.

À mes frères Abderrahman et Abdelwaheb, ainsi qu'à mes sœurs Amina et Rafika, qui ont partagé avec moi les joies et les défis de cette aventure. Leurs encouragements et leur présence ont été précieux.

À ma famille, les MIRAOUI et les ALI DAHMANE, sources d'inspiration et de soutien constants, je vous suis infiniment reconnaissante pour votre amour et votre soutien inestimable.

Et enfin, à mes amies, qui ont illuminé mes journées et rendu cette expérience encore plus mémorable. Leurs rires et leur amitié ont été un cadeau inestimable.

REMERCEMENTS

Je tiens tout d'abord à exprimer ma profonde gratitude envers mon encadrant, Prof BENDIMERAD Fethi Tarik, pour sa guidance éclairée, son soutien indéfectible et sa patience tout au long de cette recherche. Ses conseils précieux ont été une source d'inspiration et de motivation.

Un grand merci également à ma co-encadrante, Mme BENOSMAN Meryem Mamia pour sa collaboration précieuse, son expertise et ses encouragements constants. Sa présence a été d'une aide inestimable dans la réalisation de ce mémoire.

Je souhaite adresser mes remerciements aux membres du jury, Mr .MERIAH Sidi Mohammed et Mr. DERRAZ Fouad pour leur temps, leur expertise et leurs précieuses remarques qui ont contribué à améliorer la qualité de ce travail.

À tous ceux qui ont contribué de près ou de loin à la réalisation de ce mémoire, je vous adresse mes plus sincères remerciements.

TABLE DES MATIERES

Dédicaces -----	3
Remercîments -----	4
Table des matières -----	i
Liste des figures -----	i
Liste des tableaux -----	i
Résumé -----	i
Abstract -----	i
الملخص -----	i
Introduction générale -----	1
Chapitre I : Généralités sur les Amplificateurs de Puissance.	
I.1. Introduction -----	3
I.2. amplificateurs de puissance -----	3
I.3. Classes de fonctionnement -----	5
I.4. Non-linéarités des amplificateurs -----	6
I.4.1. Effets AM/AM -----	6
Région linéaire -----	7
Région de compression -----	7
Région de saturation -----	8
I.4.2. Effets AM/PM -----	9
I.5. Modélisation des distorsions non linéaires dans les amplificateurs de puissance -----	10
I.5.1. Modèles sans effet mémoire -----	10
I.5.1.1. Modèle polynomial -----	10
I.5.1.2. Modèle de Saleh -----	11
I.5.1.3. Modèle de Ghorbani -----	11
I.5.1.4. Modèle de Rapp -----	12

I.5.2. Modèle avec effet mémoire -----	12
I.6. Systèmes non linéaires orientés blocs-----	13
I.7. Efficacité énergétique -----	15
I.7.1. Réduction du PAPR -----	16
I.7.2. Linéarisation de l'amplificateur de puissance -----	16
I.8. Conclusion-----	17
Chapitre 2 : Solutions pour corriger les non-linéarités	
II.1. Introduction-----	19
II.2. Les deux familles de linéariseur-----	19
II.3. Techniques de linéarisation -----	21
II.3.1. Feedforward -----	21
II.3.2. Feedback -----	23
II.3.3. Prédistorsion -----	24
II.3.3.1. Prédistorsion analogique -----	26
II.3.3.2. Prédistorsion numérique -----	27
II.3.3.2.1. Modélisation de la DPD -----	28
II.3.3.2.2. Architecture d'Apprentissage Indirect (ILA) -----	29
II.3.3.2.3. Les approches de pointe -----	29
II.4. Conclusion -----	31
Chapitre 3 : Intelligence Artificielle pour le système de communication	
III.1. Introduction-----	33
III.2. Réseaux de neurones-----	33
III.2.1. Neurone -----	34
III.3. Apprentissage des réseaux de neurones -----	35
III.4. Choix d'une architecture de réseaux de neurones dans le cadre de la linéarisation par prédistorsion -----	36

III.5. Réseaux de neurones supervisés non-bouclés -----	36
III.5.1. Propriétés fondamentales -----	36
III.6. Modèles des réseaux de neurones -----	37
III.6.1. Perceptrons multicouches -----	37
III.6.2. Réseaux de Neurones Récurentiels -----	38
III.6.3. Réseaux de Neurones Convolutifs -----	39
III.7. Prédistorsion numérique basé sur les réseaux de neurones -----	40
III.7.1. Réseau de neurones pour la DPD AM/AM -----	41
III.7.2. Réseau neuronal pour la DPD AM/PM -----	42
III.8. Conclusion -----	43
Chapitre 4 : DPD basée sur les réseaux de neurones pour la linéarisation d'un amplificateur avec effet mémoire.	
IV.1. Introduction -----	45
IV.2. Système modèle -----	45
IV.3. Résultats et discussion -----	46
IV.3.1. Paramètres de simulation -----	46
IV.4. Conclusion et perspectives -----	53
Conclusion Générale -----	56
Bibliographie -----	i

LISTE DES FIGURES

Figure I. 1 : Bilan de puissance d'un amplificateur de puissance.....	4
Figure I. 2 : Caractéristique non-linéaire du « AP » AM/AM	7
Figure I. 3 : Caractéristique AM/PM	9
Figure I. 4 : Modèle de Hammerstein	Error! Bookmark not defined.
Figure I. 5 : Modèle de Wiener	14
Figure I. 6 : Différents systèmes BONL	15
Figure II. 1 : Positionnement des deux familles de linéariseurs	20
Figure II. 2 : Structure Feedforward.....	22
Figure II. 3 : Structure Feedback	23
Figure II. 4 : Schéma d'un système de linéarisation mettant en œuvre une prédistorsion adaptative.....	25
Figure II. 5 : Fonction de transfert du DPD, de l'amplificateur de puissance et du système résultant.....	26
Figure II. 6 : Schéma de principe d'un linéariseur analogique.	27
Figure II. 7 : Architecture d'Apprentissage Indirect (ILA).....	29
Figure III. 1: Illustration d'un neurone biologique (gauche) et d'un neurone formel (droite).....	34
Figure III. 2 : Représentation d'un réseau de neurones non-bouclé à n entrées, une couche	35
Figure III. 3 : Couche récurrente - $\mathbf{x1:t}$ représente la séquence d'entrée, indexée par le temps t . $\mathbf{s1:t}$ désigne le vecteur d'état et $\mathbf{h1:t}$ les sorties.	39
Figure III. 4 : Principe de fonctionnement d'une couche convolutionnelle.	40
Figure III. 5 : DPD pour la distorsion AM/AM	41
Figure III. 6 : DPD pour la distorsion AM/PM.....	42

Figure IV. 1 : Schéma d'un Réseau MLP	46
Figure IV. 2 : AM/AM du modèle d'Hammerstein	47
Figure IV. 3 : AM/AM du modèle d'Hammerstein après DPD	48
Figure IV. 4 : Fonction inverse AM/AM de la DPD	49
Figure IV. 5 : AM/PM du modèle d'Hammerstein	49
Figure IV. 6 : AM/PM du modèle d'Hammerstein après DPD.....	50
Figure IV. 7 : Fonction inverse AM/PM de la DPD	51
Figure IV. 8 : Constellation sans DPD.....	51
Figure IV. 9 : Constellation après DPD	52
Figure IV. 10 : Taux d'erreur binaire BER	53

LISTE DES TABLEAUX

Tableau I. 1 : Présentation des classes de fonctionnement	6
Tableau IV. 1 : Paramètres de simulations.....	46

RESUME

L'essor des télécommunications exige des transmissions de données à haut débit avec une qualité irréprochable. Les amplificateurs de puissance (APs), essentiels mais sujets à des non-linéarités près de leur zone de saturation, posent des défis majeurs. Ce mémoire propose une prédistorsion numérique basée sur l'intelligence artificielle (NNDPD) pour corriger ces distorsions. Nos résultats montrent une amélioration significative de la linéarisation des APs, une réduction du taux d'erreur binaire, et une bonne correction de la constellation, démontrant l'efficacité de notre approche pour optimiser les performances des réseaux de télécommunications.

Mots clés: Amplificateur de puissance, Pré-distorsion numérique, Efficacité énergétique, Réseaux de neurone.

ABSTRACT

The growth of telecommunications necessitates high-speed data transmissions with impeccable quality. Power amplifiers (PAs), crucial yet susceptible to nonlinearities near their saturation zone, present significant challenges. This paper proposes an Artificial Intelligence-based digital predistortion (AI-DPD) to rectify these distortions. Our findings demonstrate a noteworthy enhancement in PA linearization, a decrease in bit error rate, and proficient constellation correction, affirming the efficacy of our approach in optimizing telecommunication network performance.

Keywords: Power amplifier, Digital predistortion, Energy efficiency, Neural networks.

الملخص

تطلب ازدهار الاتصالات عمليات نقل بيانات عالية السرعة بجودة ممتازة. تمثل المضخمات تحديات كبيرة وهي مكونة أساسية لكنها عرضة للتشوهات غير الخطية بالقرب من منطقة التشبع الخاصة بها، يقترح هذا البحث نظام التشويه الرقمي المسبق المعتمد على الذكاء الاصطناعي لتسوية هذه التشوهات. تظهر نتائجنا تحسناً كبيراً في تسوية المضخمات، وتقليل معدل خطأ البت، وتعزيز جودة تشكيلات الإشارة، مما يثبت فعالية نهجنا في تحسين أداء شبكات الاتصالات

الكلمات الرئيسية: مكبر الطاقة، التحريف الرقمي المسبق، كفاءة الطاقة، الشبكات العصبية

INTRODUCTION GENERALE

INTRODUCTION GENERALE

Les réseaux de télécommunications constituent un élément fondamental de notre société moderne, fournissant des moyens essentiels de communication et de connectivité à travers le monde. Dans ce contexte, les amplificateurs de puissance jouent un rôle crucial en permettant la transmission efficace des signaux à travers ces réseaux. De plus, l'amplificateur de puissance est le composant le plus gourmand en énergie dans les systèmes de transmission. Cependant, les APs présentent souvent des distorsions non linéaires qui peuvent compromettre les performances globales des systèmes de télécommunications.

Dans ce mémoire, nous nous concentrons sur le développement d'une solution innovante pour surmonter ces défis : la prédistorsion numérique basée sur l'intelligence artificielle. Notre objectif principal est de linéariser les distorsions des APs en utilisant des techniques avancées d'apprentissage automatique pour améliorer l'efficacité du signal dans les réseaux de télécommunications.

Dans le premier chapitre, nous présenterons une vue d'ensemble des amplificateurs de puissance, en mettant en lumière leur importance dans les réseaux de télécommunications et les défis associés à leurs non-linéarités. Ensuite, dans le deuxième chapitre nous explorerons les différentes solutions proposées pour corriger ces non-linéarités, mettant en évidence les limites des approches traditionnelles.

Dans le troisième chapitre, nous explorerons le domaine de l'intelligence artificielle appliquée aux systèmes de communication. Nous examinerons les principes fondamentaux des réseaux de neurones et d'autres techniques d'apprentissage automatique, ainsi que leur potentiel pour améliorer les performances des réseaux de télécommunications.

Le quatrième chapitre, se concentrera sur notre contribution principale : la prédistorsion numérique basée sur les réseaux de neurones pour la linéarisation des amplificateurs avec effet mémoire. Nous décrirons notre approche méthodologique, les expérimentations menées et les résultats obtenus, démontrant ainsi l'efficacité de notre méthode pour améliorer la qualité du signal dans les réseaux de télécommunications.

En conclusion, ce mémoire vise à apporter une contribution significative à l'optimisation des performances des réseaux de télécommunications, en proposant une solution novatrice pour surmonter les distorsions non linéaires des amplificateurs de puissance. En combinant l'expertise en réseaux de neurones et en télécommunications, nous ouvrons de nouvelles Perspectives pour la linéarisation des APs.

CHAPITRE I : GENERALITES SUR LES AMPLIFICATEURS DE PUISSANCE.

I.1. Introduction-----	3
I.2. Amplificateurs de puissance -----	3
I.3. Classes de fonctionnement-----	5
I.4. Non-linéarités des amplificateurs-----	6
I.5. Modélisation des distorsions non linéaires dans les amplificateurs de puissance-----	10
I.6. Systèmes non linéaires orientés blocs-----	13
I.7. Efficacité énergétique-----	15
I.8. conclusion	

I.1. INTRODUCTION

Les amplificateurs de puissance jouent un rôle essentiel dans les systèmes de communication sans fil, où ils sont chargés d'amplifier les signaux électriques afin de les rendre suffisamment puissants pour être transmis sur de longues distances. Ces composants sont omniprésents dans les stations de base des réseaux cellulaires, les émetteurs-récepteurs sans fil, les satellites et de nombreux autres dispositifs de communication. La qualité de l'amplification effectuée par ces amplificateurs est cruciale pour la performance globale du système de communication.

Dans ce premier chapitre, nous explorons les amplificateurs de puissance en commençant par une présentation des principes de fonctionnement. Ensuite, nous examinons les différents types d'amplificateurs disponibles, ainsi que leurs caractéristiques distinctives. Nous analysons également les caractéristiques fondamentales des amplificateurs de puissance, telles que leur gain, leur efficacité et leur linéarité, qui sont des facteurs clés dans leur conception et leur utilisation pratique, ainsi que les différents modèles qui les décrivent.

Une attention particulière est accordée aux distorsions et aux non-linéarités, qui représentent des défis majeurs dans le fonctionnement des amplificateurs de puissance. Ces phénomènes peuvent altérer les signaux amplifiés, entraînant une dégradation de la qualité du signal et des performances globales du système de communication. Comprendre ces distorsions et non-linéarités est crucial pour développer des techniques efficaces de correction et de linéarisation des amplificateurs de puissance, ce qui sera exploré en détail dans les chapitres suivants de ce mémoire.

I.2. AMPLIFICATEURS DE PUISSANCE

Un amplificateur de puissance peut être considéré comme un convertisseur de puissance continu (DC) à radiofréquence (RF), transformant l'énergie fournie par l'alimentation en une énergie oscillante, qui s'ajoute au signal RF d'entrée (figure I.1). Cependant, une partie de cette puissance continue n'est pas convertie en RF, mais plutôt dissipée thermiquement par le dispositif. [1]

La relation (I.1) donne le bilan de puissance lors de l'amplification d'un signal. Comme il n'est pas possible d'obtenir un transfert total de l'énergie vers le signal amplifié en raison des pertes dans le système, la notion de rendement est introduite pour quantifier l'efficacité de cette conversion d'énergie. [2]

Nous avons :




Figure I. 1 : Bilan de puissance d'un amplificateur de puissance

$$p_e + p_{dc} = p_s + p_{diss} \quad (\text{I. 1})$$

Les puissances d'entrée p_e et d'alimentation p_{dc} sont transformées en puissance de sortie p_s et en perte p_{diss} , qui représente la puissance dissipée ou perdue.

Le gain de puissance G_p d'un amplificateur de puissance est défini comme le rapport entre la puissance d'entrée et la puissance de sortie.

$$G_p = \frac{p_s}{p_e} \quad (\text{I. 2})$$

Ici, la puissance d'entrée et la puissance de sortie sont la puissance réellement délivrée à l'entrée du transistor et la puissance rayonnée par la charge de sortie.

Le gain de transducteur G_t est préféré au gain de puissance, car il prend en compte le désaccord entre l'amplificateur de puissance et le générateur.

$$G_t = \frac{p_s}{p_{gen}} \quad (\text{I. 3})$$

Où p_{gen} est la puissance disponible du générateur.

Dans la littérature, on trouve généralement deux notions de rendement :

Le rendement en puissance (l'efficacité du drain), qui représente le rapport entre la puissance de sortie et la puissance fournie par l'alimentation. Ce paramètre revêt une importance particulière car il permet d'évaluer l'efficacité de l'amplificateur tout en tenant compte de sa consommation énergétique. Sa définition est donnée par l'expression suivante :

$$\eta = \frac{p_s}{p_{dc}} \quad (\text{I. 4})$$

Le rendement en puissance ajoutée, également crucial, intègre la puissance d'entrée dans son calcul. Comme le rendement en puissance, il évalue la consommation de l'amplificateur. Sa formulation est la suivante :

$$\eta = \frac{p_s - p_e}{p_{dc}} = \frac{p_s \left(1 - \frac{1}{G_p}\right)}{p_{dc}} \quad (\text{I.5})$$

Pour des gains de puissance importants (plus de 12 dB), le rendement ajouté de puissance est très proche de l'efficacité du drain. Dans les amplificateurs de puissance commerciaux, plusieurs étages d'amplification sont généralement utilisés afin d'atteindre plus de 20 dB de gain.

Le rendement en puissance ajoutée est utilisé pour évaluer l'efficacité d'un composant. Cependant, dans le domaine de la recherche, où l'intérêt se porte principalement sur les performances intrinsèques d'un composant et non sur la création d'un amplificateur prêt à l'emploi, les amplificateurs de puissance sont généralement à un seul étage, avec un gain relativement faible. L'efficacité du drain devient alors la principale mesure d'efficacité.

I.3. CLASSES DE FONCTIONNEMENT

Pour les amplificateurs de puissance constitués de plusieurs étages d'amplification à base de transistors, la notion de rendement est intimement liée aux caractéristiques statiques des transistors. Selon la manière dont le transfert d'énergie est réalisé, on distingue plusieurs classes de fonctionnement. Le tableau I.1 répertorie ces différentes classes de fonctionnement et leurs spécifications respectives. [2]

classe	Uniformité	Rendement
A	Une large plage de linéarité	Un faible rendement et une consommation d'énergie en l'absence de signal
AB	Une plage étendue de linéarité avec un rendement satisfaisant, établissant ainsi un compromis entre les caractéristiques	Une consommation réduite en l'absence de signal

	des classes A et B	
B	Un rendement notable	production d'harmoniques paires
F	rendement élevé	génération d'harmoniques importantes

Tableau I. 1 : Présentation des classes de fonctionnement

I.4. NON-LINEARITES DES AMPLIFICATEURS

Un amplificateur est nécessaire pour propager efficacement un signal sur un canal. Pour les transmissions radio, les amplificateurs de puissance sont utilisés pour garantir que l'onde radio dispose d'une puissance adéquate. Les fonctions de transfert non linéaires des amplificateurs présentent un point de compression, qui sépare la zone linéaire, où les variations du signal de sortie sont proportionnelles à celles du signal d'entrée, de la zone non linéaire, où le signal de sortie est soumis à des distorsions en amplitude et en phase. [3]

Toutefois, dans la pratique, les amplificateurs radio présentent des caractéristiques non linéaires, telles que la compression en amplitude (AM/AM) et le déphasage du signal en sortie (AM/PM).

I.4.1. EFFETS AM/AM

Les effets AM/AM, ou conversion d'amplitude à amplitude, se réfèrent aux changements dans l'amplitude du signal de sortie d'un amplificateur en fonction de l'amplitude du signal d'entrée. Lorsqu'un amplificateur est soumis à des signaux d'entrée de différentes amplitudes, sa réponse en amplitude peut varier de manière non linéaire. Typiquement, cela se traduit par une distorsion de la relation linéaire entre l'amplitude du signal d'entrée et l'amplitude du signal de sortie.

Par exemple, dans un amplificateur idéal, une augmentation linéaire de l'amplitude du signal d'entrée devrait correspondre à une augmentation proportionnelle de l'amplitude du signal de sortie. Cependant, en raison des caractéristiques non linéaires des composants de l'amplificateur, cette relation peut être altérée. Dans certains cas, une augmentation de l'amplitude du signal d'entrée peut entraîner une saturation de l'amplificateur, où le gain diminue et le signal de sortie devient aplati.

Les effets AM/AM sont courants dans de nombreux types d'amplificateurs de puissance, en particulier ceux utilisés dans les systèmes de communication sans fil. Ils peuvent causer des

distorsions indésirables dans le signal de sortie, ce qui affecte la qualité globale de la transmission.

La courbe de la puissance de sortie en fonction de la puissance d'entrée, également appelée caractéristique amplitude/amplitude ou conversion AM/AM, illustre cette variation (voir figure I.2).




Figure I. 2 : Caractéristique non-linéaire d'AP AM/AM

Sur la Figure I.2, nous présentons une caractéristique typique AM/AM d'un AP pour illustrer les régimes de fonctionnement de ce dernier. La caractéristique peut être divisée en trois régions majeures :

REGION LINEAIRE

Comme son nom l'indique, la relation entre l'entrée et la sortie est parfaitement linéaire. Ainsi, la sortie correspond à l'entrée multipliée par le gain de l'AP.

REGION DE COMPRESSION

Dans cette zone, le gain de l'AP commence à diminuer en raison de la non-linéarité. Par conséquent, on observe que la sortie n'est plus proportionnelle à l'entrée. Plus l'amplitude d'entrée est élevée, plus la distorsion dans la zone de compression est importante. Pour

évaluer la compression du gain, nous mesurons souvent le point de compression à 1 dB. Comme le montre la Figure I.2, $p_{1dB,in}$ représente l'amplitude d'entrée où il y a une différence de 1 dB entre l'amplitude de sortie et un amplificateur linéaire. En d'autres termes, il y a une diminution de 1 dB du gain du PA.

REGION DE SATURATION

Lorsque l'amplitude d'entrée devient trop élevée, l'AP entre dans un régime de saturation où la non-linéarité devient sévère. Finalement, l'amplitude de sortie devient constante à un certain point.

Pour atténuer ou du moins réduire les effets indésirables résultant de la non-linéarité des amplificateurs, il est souvent nécessaire de surdimensionner l'amplificateur, c'est-à-dire de prendre du recul afin d'opérer dans une région linéaire ou à proximité de celle-ci. Ce recul est généralement réalisé par rapport au point de compression à 1 dB ou par rapport à la puissance de saturation. Les grandeurs utilisées pour quantifier ce dimensionnement de l'amplificateur sont le recul d'entrée IBO et le recul de sortie OBO.

Soit $p_{s,1dB}$ la puissance de sortie au point de compression à 1 dB et $p_{e,1dB}$ la puissance d'entrée correspondante. La grandeur IBO, souvent exprimée en dB, est le rapport entre la puissance d'entrée au point de compression à 1 dB (ou de la puissance de saturation ramenée à l'entrée) sur la puissance moyenne d'entrée p_e du signal. [2]

$$IBO = \frac{p_{e,1dB}}{p_e} \quad \text{ou} \quad IBO(dB) = p_{e,1dB}(dBm) - P_e(dBm) \quad (I. 6)$$

Ou encore :

$$IBO = \frac{p_{e,sat}}{p_e} \quad \text{ou} \quad IBO(dB) = p_{e,sat}(dBm) - P_e(dBm) \quad (I. 7)$$

De manière similaire, le paramètre OBO est défini comme le rapport entre la puissance de sortie au point de compression à 1 dB (ou de la puissance de saturation) et la puissance moyenne p_s de sortie du signal.

$$OBO = \frac{p_{s,1dB}}{p_s} \quad \text{ou} \quad OBO(dB) = p_{s,1dB}(dBm) - P_s(dBm) \quad (I.8)$$

Ou encore :

$$OBO = \frac{p_{s,sat}}{p_s} \quad \text{ou} \quad OBO(dB) = p_{s,sat}(dBm) - P_s(dBm) \quad (I.9)$$

I.4.2. EFFETS AM/PM

Les distorsions AM/AM, telles que la compression du gain, sont bien comprises, mais les distorsions AM/PM, où la phase est affectée par l'amplitude, sont moins évidentes. Elles peuvent être dues aux capacités de jonction des transistors, comme la capacité base-émetteur d'un transistor bipolaire, qui peut varier avec l'amplitude du signal. Cela entraîne un déphasage de l'enveloppe du signal de sortie selon l'amplitude d'entrée, créant une distorsion de phase. En termes de spectre en fréquence, les effets AM/PM peuvent modifier la phase de la porteuse, ajoutant du contenu hors bande, même pour un signal modulé en amplitude sans distorsion. Cette modulation de phase peut affecter les constellations IQ lors de la démodulation du signal, augmentant ainsi l'erreur vectorielle moyenne. [4]

La courbe représentée dans la figure I.3 illustre le décalage de phase entre le signal de sortie et le signal d'entrée d'un amplificateur. Cette caractéristique est souvent désignée sous le nom de conversion AM/PM, mettant en évidence la variation du déphasage en fonction de l'amplitude du signal. En d'autres termes, elle montre comment le déphasage du signal de sortie est affecté par l'amplitude du signal d'entrée.




Figure I. 3 : Caractéristique AM/PM

Un AP présente des caractéristiques de transfert non linéaires qui perturberont l'amplitude et la phase d'un signal entrant en fonction de l'amplitude d'entrée de ce dernier.

I.5. MODELISATION DES DISTORSIONS NON LINEAIRES DANS LES AMPLIFICATEURS DE PUISSANCE

La modélisation des effets de non-linéarités des amplificateurs de puissance vise à développer un modèle mathématique ou physique permettant de représenter ou d'approximer ces distorsions non linéaires en amplitude et en phase. [5]

L'amplificateur de puissance est le composant le plus énergivore et également une source principale de non-linéarités dans un système de communication. Ainsi, la conception de modèles d'AP a été un axe de recherche pour les chercheurs au cours des dernières décennies. [3]

En termes de modélisation, il existe deux types de modèles d'AP: les modèles sans effet mémoire et les modèles avec effets de mémoire.

I.5.1. MODELES SANS EFFET MEMOIRE

La réponse en fréquence de l'AP présente des caractéristiques plates sur toute sa plage de fréquences de fonctionnement, la non-linéarité est dite être indépendante de la fréquence ou sans mémoire.

Divers modèles d'amplificateurs de puissance ont été développés dans la littérature. Parmi eux, on retrouve principalement le modèle polynomial, ainsi que quelques modèles non polynomiaux comme le modèle de Rapp, le modèle de Ghorbani et le modèle de Saleh. [6]

Par la suite ces modèles sont détaillés avec $A(r)$ correspond à la non-linéarité d'amplitude, exprimée par la fonction de gain en amplitude, décrivant comment le module du signal de sortie évolue en fonction de celui de l'entrée. $\phi(r)$ représente la non-linéarité de phase ou la fonction de phase, décrivant le déphasage du signal de sortie par rapport au module de l'entrée.

I.5.1.1. MODELE POLYNOMIAL

Le modèle polynomial a été introduit pour représenter de manière approximative les caractéristiques de gain et de phase par des fonctions polynomiales. Ces équations sont définies comme suit.

$$A(r) = \sum_{i=0}^{p_1} \alpha_i r^i \quad (\text{I.10})$$

$$\phi(r) = \sum_{i=0}^{p_2} \beta_i r^i \quad (\text{I.11})$$

Les ordres des polynômes de la fonction de gain et de phase sont respectivement définis par p_1 et p_2 . Ces valeurs sont choisies en fonction de la forme de la fonction à approximer. À mesure que p_1 et p_2 augmentent, l'approximation devient plus précise, mais cela rend le modèle plus complexe et peut augmenter le risque de divergence lors de l'extraction des paramètres $[\alpha_0 \alpha_1 \dots \alpha_{p_1}]$ et $[\beta_0 \beta_1 \dots \beta_{p_2}]$.

I.5.1.2. MODELE DE SALEH

Proposition de Saleh pour les amplificateurs à Tube à Onde progressive (TOP) ou TWTA (Travelling Wave Tube Amplifiers) fréquemment utilisés dans les systèmes de communications par satellite. Le modèle, décrit par les équations vise à représenter les caractéristiques AM/AM et AM/PM.

$$A(r) = \frac{\alpha_a r}{1 + \beta_a r^2} \quad (\text{I.12})$$

$$\phi(r) = \frac{\alpha_p r^2}{1 + \beta_p r^2} \quad (\text{I.13})$$

Le modèle se compose de quatre paramètres : (α_a, β_a) pour la fonction de gain en amplitude et (β_p, α_p) pour la fonction de phase.

I.5.1.3. MODELE DE GHORBANI

Ghorbani a avancé un modèle plus général s'appuyant sur le modèle de Saleh. Ce modèle, exprimé par les équations, requiert quatre paramètres $(\alpha_1, \alpha_2, \alpha_3, \alpha_4)$ pour approximer la fonction de non-linéarité en amplitude AM/AM, ainsi que quatre autres $(\beta_1, \beta_2, \beta_3, \beta_4)$ pour celle en phase AM/PM.

$$A(r) = \frac{\alpha_1 r^{\alpha_2}}{1 + \alpha_3 r^{\alpha_2}} + \alpha_4 r \quad (\text{I.14})$$

$$\phi(r) = \frac{\beta_1 r^{\beta_2}}{1 + \beta_3 r^{\beta_2}} + \beta_4 r \quad (\text{I.15})$$

I.5.1.4. MODELE DE RAPP

Rapp a présenté un autre modèle décrivant les amplificateurs à semi-conducteurs (SSPA pour Solid State Power Amplifier) utilisés dans les systèmes radio mobiles.

$$A(r) = \frac{v_r}{(1 + \left(\frac{v_r}{A_0}\right)^{2s})^{\frac{1}{2s}}} \quad (\text{I.16})$$

$$\emptyset(r) = 0 \quad (\text{I.17})$$

Ce modèle est caractérisé par trois paramètres principaux : l'amplitude de saturation en sortie (A_0), qui représente le niveau maximal auquel le signal peut être amplifié sans distorsion significative ; l'ordre de non-linéarité (s), qui décrit la complexité de la relation entre l'amplitude d'entrée et de sortie ; et enfin le gain dans le domaine linéaire (v_r), qui indique la relation linéaire entre l'amplitude d'entrée et de sortie lorsque le signal est faible.

Il est important de noter que ce modèle se concentre exclusivement sur la distorsion d'amplitude et ne prend pas en compte les effets de non-linéarité de phase. Cela signifie qu'il est particulièrement adapté pour décrire les amplificateurs dont la principale source de distorsion provient de la réponse non linéaire de l'amplitude du signal.

I.5.2. MODELE AVEC EFFET MEMOIRE

Lorsque la caractéristique de l'AP dépend de la fréquence, il présente des effets de mémoire. En d'autres termes, la sortie de l'AP dépend à la fois des entrées actuelles et passées. Ce genre de phénomène peut être observé lors de l'utilisation de signaux à large bande. Par conséquent, les modèles sans mémoire deviennent inadéquats pour représenter ce phénomène. Une façon populaire de modéliser les non-linéarités et les effets de mémoire des APs est d'utiliser des séries de Volterra. En temps discret, la sortie y_n du AP est donnée par :

$$y_n = \sum_{k=1}^k y_{k,n} \quad (\text{I.18})$$

Où :

$$y_{k,n} = \sum_{i_1=0}^{M-1} \dots \sum_{i_k=0}^{M-1} j_k(i_1, \dots, i_k) \prod_{j=1}^k x_{n,k-i_j} \quad (\text{I.19})$$

x_n Désigne l'entrée en temps discret. $j_k(i_1, \dots, i_k)$ représente le noyau de Volterra d'ordre K et M désigne la profondeur de la mémoire.

En utilisant ces équations, nous pouvons modéliser avec précision toutes les non-linéarités d'un AP. Cependant, cela demande beaucoup de calculs en raison de la profondeur de la mémoire et de la taille du noyau. En outre, il existe d'autres modèles permettant de représenter les APs avec des effets de mémoire, tels que les modèles de Wiener et Hammerstein. Alternativement, on peut également utiliser un modèle polynomial de mémoire qui est une troncature de la série de Volterra. Le principal avantage de ce modèle est qu'il est moins complexe que les autres tout en maintenant une bonne modélisation des effets de mémoire. [3]

I.6. SYSTEMES NON LINEAIRES ORIENTES BLOCS

Les non-linéarités et les effets de mémoire peuvent être modélisés séparément par l'association de blocs dynamiques linéaires invariants dans le temps (LTI) et de blocs non linéaires statiques : système non linéaire orienté bloc (BONL)

Les modèles Hammerstein, Wiener et Wiener-Hammerstein sont largement utilisés dans les systèmes non linéaires orientés blocs, et leurs algorithmes d'identification sont bien étudiés. [7] Supposons que $u(n)$ soit le signal d'entrée et $x(n)$ soit le signal de sortie du prédistorteur. Si nous modélisons la partie non linéaire avec un polynôme, le modèle Hammerstein est donné par les équations:

$$w(n) = \sum_{k=0}^K a_k u(n) |u(n)|^k \quad (\text{I.20})$$

$$x(n) = \sum_{l=0}^L b_l w(n-l) \quad (1.21)$$

Où $w(n)$ est le signal intermédiaire entre les deux étapes du modèle.




Figure I. 4 : Modèle d'Hammerstein




Figure I. 4 : Modèle de Wiener

Dans le modèle de Hammerstein, il représente la sortie de la partie non linéaire et l'entrée de la partie LTI comme le montre la Figure I.4. Dans le modèle de Wiener, il représente la sortie de la partie LTI et l'entrée de la partie non linéaire comme le montre la Figure I.5.

La partie non linéaire sans mémoire est représentée par (I.20). Le système LTI est représenté par (I.21). Et le modèle de Wiener est donné par (I.22) et (I.23).

$$w(n) = \sum_{l=0}^L a_l u(n-l) \quad (\text{I.22})$$

$$x(n) = \sum_{k=0}^K b_k w(n) |w(n)|^k. \quad (\text{I.23})$$

Le système LTI est représenté par l'équation (I.22), et la partie non linéaire sans mémoire est représentée par l'équation (I.23).

Le modèle de Wiener-Hammerstein est donné par les équations (I.24), (I.25) et (I.26).

$$w(n) = \sum_{l=0}^L a_l u(n-l) \quad (\text{I.24})$$

$$s(n) = \sum_{k=0}^K b_k w(n) |w(n)|^k \quad (\text{I.25})$$

$$x(n) = \sum_{m=0}^M c_m u(n-m) \quad (\text{I.26})$$

Il s'agit d'une non-linéarité sans mémoire prise entre deux filtres linéaires, comme illustré dans la Figure I.6. Le modèle de Wiener et le modèle de Hammerstein peuvent être considérés comme des cas particuliers du modèle de Wiener-Hammerstein.




Figure I. 5 : Différents systèmes BONL

Avec différentes combinaisons, nous pouvons également dériver le modèle Hammerstein-Wiener, le modèle Wiener parallèle, le modèle Hammerstein parallèle, le modèle Wiener-Hammerstein parallèle comme le montre la figure I.6.

I.7. EFFICACITE ENERGETIQUE

L'efficacité énergétique de l'amplificateur de puissance est maximale près de sa saturation. Cependant, l'amplificateur de puissance présente également des non-linéarités sévères qui vont dégrader le signal reçu. Pour éviter ce problème, il est souvent envisagé de réduire la puissance moyenne du signal. Cette opération, appelée décrochage, permet d'atteindre le régime linéaire

de l'amplificateur de puissance, évitant ainsi les non-linéarités. Cependant, en procédant ainsi, l'efficacité énergétique du composant matériel chute à son minimum. [3]

Ensuite, pour améliorer l'efficacité énergétique globale du système, une optimisation conjointe de la consommation d'énergie et des non-linéarités doit être effectuée. En d'autres termes, il convient de corriger les non-linéarités de l'amplificateur de puissance, c'est-à-dire de le linéariser, tout en maintenant son efficacité maximale.

I.7.1. REDUCTION DU PAPR

Une façon d'améliorer l'efficacité de l'amplificateur de puissance est de minimiser l'opération de retour en arrière. En faisant cela, l'efficacité de l'amplificateur de puissance pourrait être améliorée car il pourrait fonctionner à des puissances d'entrée plus élevées sans saturation. Pour atteindre cet objectif, une technique courante consiste à réduire le PAPR des formes d'onde, ce qui conduit à moins de fluctuations de puissance du signal. Par exemple, dans les systèmes OFDM, de nombreuses études ont été menées pour résoudre le problème du PAPR. En particulier, le clipping, la séquence de transmission partielle et le mapping sélectionné sont prouvés pour réduire avec succès le PAPR de l'OFDM. En outre, il est également possible de considérer l'optimisation de la constellation, bénéficiant d'une complexité réduite par rapport aux schémas classiques de réduction du PAPR. En outre, des études sont également menées pour proposer de nouvelles formes d'onde ayant un PAPR plus faible par rapport à l'OFDM. Ainsi, toutes ces différentes techniques permettent d'utiliser des formes d'onde avec un PAPR plus faible, augmentant alors l'efficacité de l'amplificateur de puissance grâce à un retour en arrière réduit. Cependant, même si l'amplificateur de puissance peut être exploité près de sa saturation, il présentera toujours des non-linéarités.

I.7.2. LINEARISATION DE L'AMPLIFICATEUR DE PUISSANCE

Pour compenser les non-linéarités de l'AP, différentes méthodes sont disponibles. Trois grandes techniques sont généralement utilisées pour corriger les non-linéarités de l'AP : le "feedforward", le "feedback" et la pré-distorsion.

Actuellement, la prédistorsion numérique (DPD) demeure la méthode la plus populaire. Elle implique l'ajout d'un module avant l'AP de manière à rendre le système résultant, comprenant à la fois le DPD et l'AP, linéaire. Bien que largement adoptée, des recherches continuent d'être menées pour améliorer la complexité et l'efficacité énergétique de cette méthode. De plus, les APs sont sujets à des variations temporelles telles que la température et

les fluctuations électriques, ce qui rend nécessaire une prise en compte idéale de ces effets par la pré-distorsion. [8]

I.8. CONCLUSION

Dans ce premier chapitre, nous avons exploré les différents aspects des amplificateurs de puissance, en nous concentrant sur leur fonctionnement, leurs caractéristiques non linéaires et les méthodes de modélisation de ces distorsions. Nous avons également examiné l'efficacité énergétique et les systèmes non linéaires orientés blocs. Ce chapitre présente les bases nécessaires pour comprendre les défis auxquels sont confrontés les amplificateurs de puissance et ouvre la voie à des solutions pour corriger les non-linéarités, qui seront abordées dans le prochain chapitre.

CHAPITRE 2 : SOLUTIONS POUR CORRIGER LES NON- LINEARITES

II.1. Introduction-----	19
II.2. Les deux familles de linéariseur-----	19
II.3. Techniques de linéarisation -----	21
II.4. Conclusion	

II.1. INTRODUCTION

Dans le domaine des communications sans fil, les amplificateurs de puissance jouent un rôle crucial en assurant la transmission efficace des signaux sur des canaux de communication. Toutefois, ces amplificateurs sont souvent sujets à des non-linéarités, ce qui peut entraîner des distorsions indésirables du signal transmis. Ces distorsions sont particulièrement préoccupantes dans les systèmes de communication haute performance, où la fidélité du signal est essentielle pour garantir une transmission précise et fiable des données.

Dans le chapitre précédent, nous avons examiné les caractéristiques générales des amplificateurs de puissance, ainsi que les défis posés par leurs non-linéarités. Nous avons également souligné l'importance de la linéarisation des APs pour minimiser ces distorsions et améliorer la qualité du signal transmis. Dans ce chapitre, nous nous concentrerons sur les techniques de linéarisation utilisées pour atteindre cet objectif.

Nous commencerons par explorer trois techniques de linéarisation couramment utilisées : le feedforward, le feedback et la pré-distorsion. Nous examinerons les principes de fonctionnement de chacune de ces techniques, ainsi que leurs avantages et leurs limitations. Ensuite, nous approfondirons l'étude de la prédistorsion numérique, une méthode de linéarisation prometteuse qui utilise des algorithmes numériques avancés pour anticiper et compenser les distorsions de l'amplificateur.

Ce chapitre vise à fournir une compréhension des techniques de linéarisation et de leur importance pour l'amélioration des performances des amplificateurs de puissance dans les systèmes de communication sans fil.

II.2. LES DEUX FAMILLES DE LINEARISEUR

La première famille de linéariseurs se concentre sur la linéarisation de l'amplificateur lui-même. Ce type de linéariseur est positionné juste avant l'amplificateur de puissance et agit à la fréquence de la porteuse, qui est généralement une haute fréquence. Bien qu'il soit compact, il nécessite des composants électroniques capables de fonctionner à haute fréquence sur toute la bande spectrale utilisée par l'amplificateur. De plus, les composants tels que les adaptateurs d'impédance, les isolateurs et les coupleurs doivent être dimensionnés en tenant compte de la fréquence de fonctionnement de l'amplificateur, car la performance du linéariseur dépend fortement de celle de l'amplificateur de puissance.

La deuxième famille de linéariseurs agit avant la transposition du signal en haute fréquence, c'est-à-dire à une fréquence intermédiaire ou en bande de base. Dans ce cas, la linéarisation peut être effectuée numériquement avant la modulation ou sur le signal analogique après modulation. Ce type de linéariseur agit non seulement sur les non-linéarités de l'amplificateur, mais également sur les distorsions potentielles introduites par le circuit de modulation. Une des avantages de ce type de dispositif est que les circuits électroniques utilisés en bande de base ou à fréquence intermédiaire rencontrent moins de problèmes d'adaptation d'impédance, d'isolation ou de couplage. De plus, un même circuit peut être utilisé avec plusieurs amplificateurs de puissance fonctionnant à différentes fréquences, ce qui permet de concevoir un seul linéariseur pour plusieurs AP.

Cette deuxième famille de linéariseurs peut être particulièrement intéressante pour la transmission d'informations sol-satellites. En effet, les stations solaires génèrent le signal modulé à haute fréquence à partir des données binaires à transmettre, et le signal en bande de base ou à fréquence intermédiaire peut donc être accessible dans la chaîne de transmission de ces stations. En ce qui concerne les satellites de télécommunications, l'intérêt pour cette deuxième famille de linéariseurs n'est pas immédiat, car la transposition du signal reçu à un signal en bande de base ou à fréquence intermédiaire n'est pas nécessaire dans les topologies de charges utiles actuelles. Cependant, l'utilisation de processeurs numériques à bord pourrait susciter un intérêt certain pour ce type de linéariseurs à moyen terme, tant pour les satellites de télécommunications que pour d'autres applications, telles que militaires ou de transfert de données scientifiques au sol. [6]




Figure II. 1 : Positionnement des deux familles de linéariseurs

La figure représente le positionnement de deux familles de linéariseurs dans la chaîne d'émission. En haut, le linéariseur est placé directement avant l'amplificateur de puissance, traitant le signal haute fréquence (HF) pour corriger les non-linéarités de l'amplificateur. En bas, le linéariseur est positionné avant la transposition en haute fréquence, où il traite un signal

en bande de base ou à fréquence intermédiaire (FI). Après linéarisation, le signal est transposé en haute fréquence avant d'être amplifié.

II.3. TECHNIQUES DE LINEARISATION

Pour faire face aux non-linéarités présentées par l'amplificateur de puissance, de nombreuses techniques ont été proposées afin de le linéariser. Il existe principalement trois techniques de linéarisation : feedforward, feedback et prédistorsion. Nous présentons ici quelques idées sur chaque technique.

II.3.1. FEEDFORWARD

Les archives indiquent que la technique de la rétroaction prédictive est la première forme de linéarisation RF à avoir été conçue. Elle a été inventée par Howard Black en 1923 aux Laboratoires Bell de Téléphone.

Il a eu l'idée en travaillant sur des moyens de réduire la distorsion dans les systèmes téléphoniques multiplex où de nombreuses porteuses modulées en voix sont transmises sur un seul câble téléphonique. Pour la transmission sur de longues distances, de nombreux amplificateurs doivent être utilisés. La distorsion provenant de ces amplificateurs est un problème majeur en raison de la distorsion additive de chaque amplificateur. Le concept de la rétroaction prédictive est ingénieusement simple mais plutôt complexe à mettre en œuvre. [9]

Son principe est illustré dans la Figure II.2.




Figure II. 2 : Structure Feedforward

Le processus commence par l'acheminement du signal à amplifier vers l'amplificateur principal de puissance. Ensuite, un fractionnement du signal est effectué à l'aide d'un coupleur directionnel (C1). Le signal prélevé à ce stade est comparé au signal d'entrée original afin de déterminer les différences, représentant idéalement la distorsion introduite par l'amplificateur. Cette étape constitue ce qu'on appelle la boucle de suppression de la porteuse.

Par la suite, le signal d'erreur ainsi calculé est amplifié à un niveau spécifique par un second amplificateur de puissance, choisi pour sa linéarité optimale. En parallèle, le signal de la voie de référence, qui a été retardé, est combiné avec le signal d'erreur amplifié en utilisant un coupleur en antiphase (C2). L'objectif de cette combinaison est de réduire de manière significative les distorsions produites par l'amplificateur principal.

Le succès du Feedforward réside dans son utilisation en boucle ouverte, ce qui garantit la stabilité du système et permet son utilisation même avec des signaux très larges bandes. En utilisant cette approche, l'amplificateur d'erreur n'a besoin d'être dimensionné que pour amplifier l'information de distorsion, ce qui signifie qu'il peut être beaucoup plus petit que l'amplificateur principal.

Cependant, le principal inconvénient du Feedforward réside dans les nombreux composants analogiques nécessaires, tels que les lignes à retard, les coupleurs et l'amplificateur d'erreur. Ces composants sont sujets à des imperfections en termes de phase, d'amplitude et de retard. De plus, ces imperfections peuvent apparaître progressivement avec le vieillissement des composants ou en raison de l'auto-échauffement. Pour corriger ces imperfections,

différents circuits de contrôle numérique doivent être mis en place. En d'autres termes, il est nécessaire d'utiliser des algorithmes numériques pour surveiller et ajuster en temps réel les performances du système afin de compenser les défauts des composants analogiques et de maintenir son bon fonctionnement sur le long terme. [10]

II.3.2. FEEDBACK

En raison des défis rencontrés dans l'implémentation de la technique Feedforward, Black a proposé en 1927 l'idée d'un amplificateur à rétroaction négative (Feedback) qui s'est avérée plus efficace et plus facile à mettre en œuvre. Le principe de la contre-réaction est de prendre une partie du signal de sortie, de l'inverser, puis de le réintroduire en entrée à travers une boucle de contre-réaction. Cela permet au signal de sortie de suivre plus fidèlement la forme du signal d'entrée. Grâce à ce fonctionnement en boucle fermée, les non-linéarités générées par l'amplificateur sont dynamiquement corrigées, ce qui permet de se passer d'une étude préalable approfondie des caractéristiques des amplificateurs de puissance. [11]




Figure II. 3 : Structure Feedback

Diverses méthodes d'implémentation de systèmes de linéarisation à contre-réaction ont été proposées. Deux de ces méthodes sont particulièrement intéressantes : la contre-réaction polaire (Polar Feedback) et la contre-réaction cartésienne (Cartesian Feedback). Ces deux approches permettent de travailler respectivement à fréquence intermédiaire et en bande de base, ce qui les rend adaptables à plusieurs types d'amplificateurs.

L'architecture Feedback présente toutefois quelques inconvénients. Tout d'abord, il peut être difficile de capturer le signal HF en sortie de l'amplificateur de puissance, surtout dans un système embarqué. De plus, une partie de la puissance de sortie de l'amplificateur est utilisée dans la boucle de contre-réaction, ce qui limite la puissance transmise vers l'antenne. Dans un contexte où l'optimisation de la puissance à transmettre est cruciale, cette limitation peut poser

problème. De plus, le fonctionnement en boucle fermée limite la fréquence de fonctionnement du système. Enfin, la complexité de l'implémentation du système doit être prise en compte : plus l'architecture est complexe, plus la linéarité est améliorée, mais cela entraîne une augmentation de l'encombrement et de la consommation, ainsi qu'une diminution du rendement global de l'ensemble "Linéariseur + Amplificateur".

Dans la seconde moitié du XXe siècle, avec la croissance des réseaux de télécommunications, il est devenu nécessaire d'augmenter les fréquences des signaux et leur bande passante. Dans ce contexte, les limites de la technique à contre-réaction ont commencé à apparaître progressivement. La technique Feedforward est revenue sur le devant de la scène, avec des chercheurs comme Seidel en 1971 et Bennett en 1974 qui ont utilisé cette approche pour linéariser des amplificateurs à transistors bipolaires à effet de champ (ATOP). Pendant des décennies, le Feedforward est resté l'une des techniques de linéarisation les plus populaires, utilisée dans une variété d'applications allant des systèmes audio aux applications radiofréquences.

Cependant, aujourd'hui, de nombreuses nouvelles méthodes de linéarisation sont développées, notamment celles basées sur la technique de prédistorsion. Ces nouvelles approches tentent de combiner les avantages des méthodes Feedforward et Feedback pour obtenir des performances encore meilleures dans la linéarisation des amplificateurs.

II.3.3. PREDISTORSION

La technique de prédistorsion implique de déformer le signal en amont de l'amplificateur de puissance à l'aide d'un circuit dédié. Cette déformation est conçue pour que le signal en sortie de l'amplificateur suive une caractéristique prédéfinie, souvent linéaire en termes de gain et de phase.

Pour déterminer la déformation à appliquer au signal d'entrée, une partie du signal de sortie de l'amplificateur est prélevée et analysée. Un système de calcul utilise ensuite ces informations pour établir la fonction de transfert du linéariseur à paramétrer. Ce processus peut être effectué une seule fois lors de la mise en œuvre du système, ou de manière répétée à intervalles réguliers, rendant la prédistorsion adaptative.




Figure II. 4 : Schéma d'un système de linéarisation mettant en œuvre une prédistorsion adaptative.

Dans la technique de prédistorsion, les défis liés à la capture du signal HF en sortie de l'amplificateur demeurent les mêmes que pour la technique à contre-réaction. De plus, comme pour la technique de rétroaction, une partie de la puissance de sortie de l'amplificateur est utilisée par le système de calcul, ce qui réduit la puissance fournie par l'amplificateur au système antenne.

Cependant, un système de prédistorsion fonctionne en boucle fermée, ce qui lui permet de fonctionner efficacement à des fréquences élevées. De plus, la prédistorsion peut être appliquée au signal à haute fréquence, en bande de base ou à fréquence intermédiaire. Enfin, le système peut être adaptatif, ce qui signifie qu'il peut s'ajuster automatiquement aux changements dans les caractéristiques de l'amplificateur ou du signal.

En résumé, un linéariseur à prédistorsion combine les avantages des techniques Feedforward et Feedback, offrant ainsi une solution plus flexible et efficace pour la linéarisation des amplificateurs de puissance.




Figure II. 5 : Linéarisation par Prédistorsion d'un AP.

II.3.3.1. PREDISTORSION ANALOGIQUE

La prédistorsion analogique est une technique utilisée pour compenser les distorsions d'un circuit à linéariser en agissant directement sur le signal modulé à la fréquence porteuse. Elle est réalisée au moyen de composants non linéaires tels que des diodes ou des transistors. L'idée fondamentale de la prédistorsion analogique est d'induire des variations intentionnelles d'amplitude AM/AM et de phase AM/PM dans le signal, de manière à compenser les distorsions introduites par le circuit.

Le principe général de la prédistorsion analogique consiste à créer un effet d'expansion de gain en utilisant une combinaison vectorielle de deux chemins. Le premier chemin est associé au composant non linéaire, tandis que le deuxième chemin comprend un déphaseur et un atténuateur variable. Cette combinaison permet de générer des variations précises dans le signal modulé, qui compensent les distorsions du circuit à linéariser. [12]




Figure II. 6 : Schéma de principe d'un linéariseur analogique.

La prédistorsion analogique offre plusieurs avantages, notamment l'utilisation de circuits compacts à faible coût et consommation énergétique. De plus, elle permet une intégration système relativement simple, ce qui en fait une solution attrayante pour des applications à très large bande, notamment dans le domaine spatial. Cependant, un contrôle précis des effets non linéaires des composants actifs est essentiel. Sans ce contrôle, il est possible d'introduire des distorsions supplémentaires dans la chaîne de transmission, ce qui peut compromettre la qualité du signal émis. Il est donc impératif de surveiller attentivement les caractéristiques des composants actifs et de les ajuster avec précision pour garantir une prédistorsion efficace sans introduire de distorsions indésirables.

II.3.3.2. PREDISTORTION NUMERIQUE

La prédistorsion dans le domaine numérique offre des performances de linéarisation supérieures. Elle est réalisée par logiciel, en utilisant des composants numériques reprogrammables tels que les FPGA, les ASIC ou les DSP. Cette approche permet de contourner les problèmes de dispersion associés aux composants analogiques.

De plus, le système de prédistorsion numérique peut être adaptatif en ajoutant une boucle de rétroaction. Cette boucle permet de prélever une partie du signal de sortie de l'amplificateur pour mettre à jour dynamiquement le bloc de prédistorsion. Cette adaptabilité permet d'ajuster en temps réel la prédistorsion en fonction des variations du système.

La prédistorsion numérique en bande de base est indépendante de la fréquence porteuse, ce qui lui confère une grande flexibilité. Elle reste efficace dans les environnements multi-mode ou multi-bande grâce à sa capacité d'adaptation.

II.3.3.2.1. MODELISATION DE LA DPD

L'objectif de la DPD est d'appliquer une distorsion au signal de manière à ce que, lorsqu'il est amplifié par l'AP, le système résultant DPD et l'AP soit linéaire. Pour ce faire, il faut trouver la caractéristique inverse de l'AP [13]. Cela revient à :

$$H_{AP} \circ H_{PD} = I \quad (\text{II.1})$$

Où H_{PD} est la fonction de transfert de la fonction DPD, H_{AP} est la fonction de transfert de l'AP, et I est la fonction identité.

- **Théorème 1 :**

Soit $f: C \rightarrow D$ une fonction. f admet un inverse, $f^{-1}: D \rightarrow C$ si et seulement si f est bijective. Alors, nous avons :

$$f^{-1}(d) = c \leftrightarrow d = f(c) \quad (\text{II.2})$$

- **Corollaire 1 :**

Soit $f: C \rightarrow D$ une fonction bijective. Il en découle que :

$$f^{-1} \circ f = I_C, \quad \text{et}, \quad f \circ f^{-1} = I_D \quad (\text{II.3})$$

Où I_C et I_D désignent respectivement la fonction identité sur C et D .

Ainsi, pour trouver le DPD idéal de l'amplificateur de puissance, ce dernier doit avoir une fonction de transfert bijective pour dériver sa fonction DPD. En utilisant l'équation (II.3), l'équation (II.1) devient.

$$H_{PA} \circ H_{PA}^{-1} = I \quad (\text{II.4})$$

Comme exemple simplifié, nous considérons un amplificateur de puissance présentant uniquement une distorsion AM/AM. La figure II.5 présente la fonction DPD qui va linéariser l'amplificateur de puissance. Comme nous pouvons le voir, l'objectif est d'obtenir un amplificateur linéarisé. Ainsi, le défi est de dériver la caractéristique DPD.

- **Remarque 1**

Si la caractéristique de l'amplificateur de puissance n'est pas bijective, nous pouvons envisager une linéarisation par morceaux. Ce faisant, nous linéarisons des fonctions bijectives. Ensuite, il faut également représenter la caractéristique de l'amplificateur de puissance sous la forme d'une succession de fonctions bijectives.

II.3.3.2.2. ARCHITECTURE D'APPRENTISSAGE INDIRECT (ILA)

Pour dériver le module DPD, il existe deux approches appelées Architecture d'Apprentissage Direct (DLA) et Architecture d'Apprentissage Indirect (ILA). Nous ne considérerons que l'ILA pour dériver le DPD. L'approche est présentée sur la Figure II.7. Elle consiste à trouver une post-inverse de l'amplificateur de puissance en utilisant une technique d'estimation des paramètres. De plus, pour utiliser le post-distorteur comme pré-distorteur, la caractéristique de l'amplificateur de puissance doit être bijective selon l'équation (II.2)




Figure II. 7 : Architecture d'Apprentissage Indirect.

II.3.3.2.3. LES APPROCHES DE POINTE

La mise en œuvre de la DPD a été étudiée et existe depuis de nombreuses années. Il existe principalement quatre catégories de prédistorsionneurs : les tables de consultation (LUTs), les méthodes de Volterra et polynomiales, ainsi que les solutions d'apprentissage profond. Nous donnons un aperçu de chaque approche.

- **Les tables de consultation:** Ce sont des tableaux qui cartographient les valeurs d'entrée aux valeurs de sortie, décrivant ainsi une fonction mathématique discrétisée. Les LUTs sont souvent utilisés pour estimer une fonction de prédistorsion. Dans des travaux ultérieurs, les auteurs ont réalisé une étude complète sur l'utilisation des LUTs pour dériver la fonction de DPD d'un AP. L'idée générale est de discrétiser les caractéristiques AM/AM et AM/PM de l'AP, puis d'approximer la réponse linéaire pour connaître le gain de l'AP. Pour dériver la fonction inverse, il faut trouver une valeur qui, lorsqu'elle passe à travers l'AP, rend le résultat linéaire. Ainsi, les LUTs sont utilisés pour stocker les caractéristiques de l'AP, puis un algorithme trouve la compensation pour la linéariser. Cette méthode est largement utilisée pour estimer la fonction de DPD. Cependant, elle reste principalement statique et peut présenter une complexité élevée si l'on souhaite une bonne estimation du DPD.
- **Séries de Volterra :** De manière similaire à la modélisation de l'amplificateur de puissance, on peut envisager d'utiliser les séries de Volterra pour modéliser le DPD. Ensuite, il faut trouver la valeur des noyaux de Volterra. L'estimation de ces valeurs peut être réalisée à l'aide de l'algorithme des moindres carrés. Cela nécessite beaucoup de calculs, car le modèle de Volterra peut comporter un grand nombre de noyaux et peut présenter une grande profondeur de mémoire [14].
- **Estimation polynomiale :** C'est une autre technique basée sur la conception polynomiale des caractéristiques à la fois de l'amplificateur de puissance et du DPD. La conception polynomiale est souvent réalisée à l'aide de séries de Volterra tronquées, qui peuvent même modéliser des effets de mémoire. Sinon, un modèle simple proposé dans une recherche antérieure. Ainsi, pour trouver la caractéristique du prédistorsionneur, il faut trouver l'inverse d'un polynôme de n -ième ordre. L'inversion de ce type de polynôme peut être difficile à mettre en œuvre en raison de sa complexité élevée. D'autres méthodes utilisent des filtres des moindres carrés, mais ils peuvent être complexes et lents à converger, ce qui les rend peu adaptés aux applications en temps réel où la latence et l'efficacité énergétique sont importantes. Profondeur de mémoire.
- **Réseaux neuronaux :** Les réseaux neuronaux sont une technique d'apprentissage automatique qui apprend à résoudre un problème en utilisant des données. Ils sont largement utilisés pour résoudre des problèmes non linéaires. Dans le contexte de la linéarisation de l'amplificateur de puissance, les réseaux neuronaux

peuvent être utilisés pour concevoir et estimer les paramètres du DPD une technique de linéarisation de l'AP. Par rapport à d'autres approches telles que la série de Volterra, les réseaux neuronaux peuvent offrir une complexité réduite car ils nécessitent moins de paramètres pour calculer le DPD. Par exemple, dans une étude récente, les auteurs ont utilisé un réseau neuronal pour trouver le DPD en utilisant les signaux d'entrée et de sortie de l'AP, démontrant ainsi qu'un DPD précis peut être dérivé à partir de ces données. Cependant, la complexité de cette technique reste élevée en raison du paradigme de la "boîte noire" concernant la conception de l'architecture du réseau neuronal. Malgré cela, l'utilisation des réseaux neuronaux sera envisagée pour proposer un DPD à faible complexité capable de gérer les APs à variation temporelle.

II.4. CONCLUSION

Dans ce deuxième chapitre, nous avons examiné de près les linéariseurs, en nous concentrant sur les deux principales familles et les techniques de linéarisation associées. Cette exploration nous a permis de mieux comprendre comment ces outils peuvent aider à atténuer les non-linéarités des amplificateurs de puissance, améliorant ainsi leur performance dans les systèmes de communication. Maintenant, nous sommes prêts à explorer comment l'intelligence artificielle peut être utilisée pour optimiser ces systèmes dans le prochain chapitre.

CHAPITRE 3 : INTELLIGENCE ARTIFICIELLE POUR LE SYSTEME DE COMMUNICATION

III.1. Introduction-----	33
III.2. Réseaux de neurones-----	33
III.3. Apprentissage des réseaux de neurones -----	35
III.4. Choix d'une architecture de réseaux de neurones dans le cadre de la linéarisation par prédistorsion -----	36
III.5. Réseaux de neurones supervisés non-bouclés-----	36
III.6. Modèles des réseaux de neurones -----	37
III.7. Prédistorsion numérique basé sur les réseaux de neurones-----	40
III.8. Conclusion -----	43

III.1. INTRODUCTION

Dans ce chapitre, nous explorons l'application des réseaux de neurones dans le domaine de la prédistorsion numérique. Nous débutons par une présentation générale des réseaux de neurones, en expliquant comment ces modèles peuvent résoudre des problèmes complexes.

Ensuite, nous discutons des modèles spécifiques de réseaux de neurones utilisés dans notre étude, en abordant différentes configurations et architectures.

Enfin, nous présentons notre approche de prédistorsion numérique basée sur les réseaux de neurones. Nous détaillons comment ces réseaux peuvent être entraînés pour inverser les caractéristiques AM/AM et AM/PM des amplificateurs de puissance, en décrivant les architectures spécifiques développées pour ces tâches. En conclusion, ce chapitre met en lumière le potentiel des réseaux de neurones pour améliorer les performances des systèmes de communication modernes.

III.2. RESEAUX DE NEURONES

Les réseaux de neurones sont largement utilisés dans de nombreuses applications, y compris la classification, la reconnaissance de formes (comme la lecture automatique de codes postaux, la reconnaissance faciale, la détection de formes), le contrôle non destructif (comme la détection de défauts dans les rails par courant de Foucault), et la fouille de données. Ils sont également employés pour modéliser des fonctions non linéaires dans divers domaines, notamment :

- La recherche de lois générales régissant un système à partir de données limitées, permettant de prévoir son évolution (par exemple, en météorologie, démographie ou finance).
- Le traitement de données pour simplifier la prise de décision.
- La correction de transferts non linéaires. [15]

Un réseau de neurones est une composition de plusieurs neurones, organisés de manière à approximer une fonction spécifique en fonction des entrées ($\mathbf{x}_i$) et des paramètres ($\mathbf{a}_j$). Les sorties d'un réseau de neurones résultent de compositions de fonctions non linéaires appliquées aux entrées et aux paramètres externes.

Il existe deux familles de réseaux de neurones : les réseaux bouclés et les réseaux non bouclés. Concentrons-nous sur les réseaux non bouclés, également appelés réseaux de neurones à propagation avant (Feedforward Neural Networks).

Un réseau de neurones non bouclé peut être représenté graphiquement comme un ensemble de neurones connectés, où l'information circule uniquement des entrées vers les sorties, sans rétroaction. Les neurones de sortie effectuent les dernières opérations et constituent la couche de sortie. Entre les entrées et les neurones de sortie se trouvent les neurones cachés, organisés en plusieurs couches cachées. Le nombre de neurones cachés peut varier, et ils jouent un rôle central dans le réseau en effectuant des calculs intermédiaires en parallèle. Plus le nombre de neurones cachés est élevé, plus la capacité du réseau à approximer une fonction spécifique est importante.

Les réseaux non bouclés sont statiques, car le temps nécessaire pour calculer la fonction réalisée par chaque neurone est considéré comme négligeable. Toute modification des entrées est immédiatement répercutée en sortie.

III.2.1. NEURONE

Un neurone, inspiré des neurones biologiques, est une fonction paramétrable non linéaire qui prend une ou plusieurs entrées et produit une sortie. Il est représenté à gauche de la figure III.1, où un neurone biologique transmet un signal électrique de ses dendrites à son axone. À droite, un neurone formel utilise ses entrées x_i (pour i allant de 1 à n) et des paramètres externes a_j (pour j allant de 1 à k) pour calculer une fonction non linéaire bornée

$$y = f(x_1, x_2, \dots, x_n, a_1, a_2, \dots, a_n)$$




Figure III. 1: Illustration d'un neurone biologique (gauche) et d'un neurone formel (droite)

La fonction d'un neurone est influencée à la fois par ses entrées et par des paramètres externes, qui modulent sa forme non linéaire. L'intérêt des neurones réside dans leur capacité à être connectés en réseau.

La figure III.2 illustre un réseau de neurones non bouclé avec (n) entrées, une couche cachée de (N_j) neurones et (N_m) neurones de sortie. Ce réseau réalise (N_m) fonctions non linéaires des (n) variables d'entrée en composant les fonctions des neurones cachés.




Figure III. 2 : Représentation d'un réseau de neurones non-bouclé à n entrées, une couche cachée de N_j neurones et N_m neurones de sortie

Les réseaux de neurones bouclés sont de plusieurs types, partageant tous la caractéristique d'avoir un chemin qui part et revient au même neurone. Pour étudier un réseau de neurones bouclé, il est nécessaire de d'abord étudier son équivalent non bouclé. Quel que soit le type de réseau élaboré, l'étude des réseaux de neurones non bouclés reste fondamentale.

III.3. APPRENTISSAGE DES RESEAUX DE NEURONES

L'apprentissage des réseaux de neurones constitue l'étape où l'on calcule les paramètres permettant au réseau d'approximer au mieux la fonction qu'il doit réaliser. Cette fonction peut représenter divers phénomènes tels que des processus physiques, chimiques, biologiques, économiques, etc. Elle peut être parfaitement modélisée par des équations analytiques, ou simplement observée et décrite à partir d'un ensemble fini de valeurs expérimentales de sortie en fonction de valeurs d'entrée judicieusement choisies, sans que les relations sous-jacentes ne soient connues ou définies.

L'apprentissage supervisé consiste à minimiser l'erreur entre un ensemble de valeurs expérimentales et les valeurs de sortie calculées par le réseau de neurones en fonction de ses paramètres. Les réseaux de neurones à apprentissage supervisé sont utilisés pour approximer des fonctions définies analytiquement, effectuer de la modélisation statistique ou réaliser des régressions de fonctions dont la forme analytique est inconnue ou indéfinie expérimentalement.

L'apprentissage non supervisé permet de regrouper des données selon des critères de ressemblance inconnus a priori. Parmi les réseaux de neurones à apprentissage non supervisé, les cartes auto-organisatrices (ou cartes de Kohonen) sont particulièrement étudiées et utilisées, notamment dans les domaines de la visualisation et de l'analyse de données.

III.4. CHOIX D'UNE ARCHITECTURE DE RESEAUX DE NEURONES DANS LE CADRE DE LA LINEARISATION PAR PREDISTORSION

Lorsqu'il s'agit de modéliser les caractéristiques de prédistorsion en amplitude et en phase d'un linéariseur, les réseaux de neurones non-bouclés à apprentissage supervisé sont souvent privilégiés. Ils offrent une solution simple à mettre en œuvre et robuste [16]. Parmi ces architectures, le Perceptron Multi-Couches (MLP) se distingue comme l'une des plus utilisées et étudiées actuellement. Sa précision et ses succès antérieurs en font un choix pertinent pour la suite des travaux.

Ainsi, l'étude des réseaux de neurones dans le cadre de la modélisation des caractéristiques de prédistorsion se limite aux réseaux non-bouclés à apprentissage supervisé, avec une attention particulière portée au Perceptron Multi-Couches.

III.5. RESEAUX DE NEURONES SUPERVISES NON-BOUCLES

III.5.1. PROPRIETES FONDAMENTALES

Les réseaux de neurones à apprentissage supervisé possèdent une propriété remarquable : ils sont des approximateurs universels. En d'autres termes, toute fonction bornée suffisamment régulière peut être approchée de manière uniforme, avec une précision arbitraire, dans un domaine fini de l'espace de ses variables, par un réseau de neurones comportant une couche de neurones cachés en nombre fini. Ces neurones cachés partagent tous la même fonction d'activation, et le réseau dispose également d'un neurone de sortie linéaire.

De plus, un réseau de neurones non-bouclés à apprentissage supervisé, entraîné sur un ensemble fini de couples $(x_i, y(x_i))$, a la capacité d'extrapoler les valeurs intermédiaires et de réaliser ainsi une fonction continue à partir de données discrètes. Cette capacité est appelée généralisation. Bien que cette propriété puisse entraîner des erreurs d'approximation par surajustement, les réseaux de neurones non-bouclés à apprentissage supervisé demeurent d'excellents approximateurs dans un espace d'entrée bien défini.

En outre, ces réseaux sont des approximateurs parcimonieux. À précision égale, ils nécessitent moins de paramètres ajustables que les autres approximateurs universels couramment utilisés (tels que les polynômes). Plus précisément, le nombre de paramètres varie linéairement en fonction du nombre de variables de la fonction à approcher, tandis qu'il varie de manière exponentielle pour la plupart des autres méthodes d'approximation.

Enfin, les réseaux de neurones non-bouclés à apprentissage supervisé peuvent être utilisés de manière logicielle ou intégrés directement dans une application sous différentes formes : numérique, analogique, optoélectronique ou mixte.

III.6. MODELES DES RESEAUX DE NEURONES

III.6.1. PERCEPTRONS MULTICOUCHES

Les perceptrons multicouches représentent la conception initiale des réseaux de neurones artificiels (ANN), qui se composent d'au moins trois couches d'opérations. Les unités de chaque couche sont densément connectées, nécessitant ainsi la configuration d'un nombre substantiel de poids.

Nous montrons un MLP avec une couche cachées dans la Figure III.2.

Étant donné un vecteur d'entrée x , une couche standard de MLP effectue l'opération suivante :

$$y = \sigma(wx + b) \quad (\text{III. 1})$$

Où y désigne la sortie de la couche, w représente les poids, et b les biais. σ est une fonction d'activation, qui vise à améliorer la non-linéarité du modèle. [17]

σ peut prendre différentes formes, parmi lesquelles on retrouve la fonction tangente hyperbolique (tansig) et la fonction linéaire pure (purelin) ou n représente les données d'entrée au neurone :

$$\text{tansig}(n) = \frac{2}{1 + \exp(-2 * n)} - 1 \quad (\text{III. 2})$$

$$\text{purelin}(n) = n \quad (\text{III. 3})$$

Les MLP sont constitués de plusieurs couches : la couche d'entrée qui reçoit les données brutes, les couches cachées où chaque neurone de la couche précédente est connecté à chaque neurone de la couche suivante avec des poids ajustables, et la couche de sortie qui fournit la prédiction finale du modèle. L'apprentissage des MLP se fait par rétropropagation, un algorithme qui ajuste les poids en minimisant l'erreur entre la sortie prédite et la sortie réelle, impliquant des techniques d'optimisation telles que la descente de gradient stochastique (SGD). Les MLP sont largement utilisés dans divers domaines tels que la reconnaissance de formes, la classification, la régression et la modélisation de séries temporelles, grâce à leur capacité à apprendre des relations complexes entre les données d'entrée et de sortie.

III.6.2. RESEAUX DE NEURONES RECURRENTIELS

Les Réseaux de Neurones Récurentiels (RNN) sont spécialement conçus pour modéliser des données séquentielles, telles que des séries temporelles ou du texte, où des corrélations séquentielles existent entre les échantillons successifs [18]. Contrairement aux réseaux de neurones classiques, les RNN possèdent des connexions récurrentes entre les unités cachées comme montre la figure III.3, ce qui leur permet de conserver une mémoire à long terme des informations passées lors du traitement de séquences. Cette capacité à traiter des données séquentielles en tenant compte du contexte temporel fait des RNN des outils puissants pour des tâches telles que la prédiction de séries temporelles, la traduction automatique, la reconnaissance de la parole et la génération de texte. Cependant, les RNN traditionnels souffrent souvent de problèmes de disparition ou d'explosion du gradient, ce qui limite leur capacité à apprendre des dépendances à long terme. Pour remédier à ces limitations, des architectures plus avancées telles que les LSTM (Long Short-Term Memory) et les GRU (Gated Recurrent Unit) ont été développées. Ces architectures intègrent des mécanismes de porte qui permettent au modèle de réguler le flux d'informations et de contrôler l'oubli ou la mise à jour des informations stockées dans la mémoire à long terme, ce qui les rend plus efficaces pour capturer les dépendances à long terme dans les séquences.




Figure III. 3 : Couche récurrente - $x_{1:t}$ représente la séquence d'entrée, indexée par le temps t . $s_{1:t}$ désigne le vecteur d'état et $h_{1:t}$ les sorties.

III.6.3. RESEAUX DE NEURONES CONVOLUTIFS

Au lieu d'utiliser des connexions complètes entre les couches, les réseaux de neurones convolutifs (CNN ou ConvNets) utilisent un ensemble de noyaux localement connectés (filtres) pour capturer les corrélations entre différentes régions de données. Pour chaque position de la sortie, la convolution standard effectue une opération qui combine les valeurs d'entrée avec un filtre appliqué localement. Les poids des filtres sont partagés à travers différentes positions de la carte d'entrée, ce qui permet de détecter des motifs similaires dans différentes parties de l'image.

Nous illustrons le fonctionnement d'une couche convolutionnelle 2D dans la Figure III.4. Plus précisément, les entrées d'une couche CNN 2D sont des matrices 2D multiples avec différents canaux (par exemple, la représentation RGB des images, où chaque canal correspond à une composante de couleur). Une couche convolutionnelle utilise plusieurs filtres partagés à travers différentes positions pour "balayer" les entrées et produire des cartes de sortie, appelées cartes de caractéristiques. Ces cartes de caractéristiques mettent en évidence les motifs détectés par les filtres dans les différentes parties de l'image d'entrée.

En général, si les entrées et les sorties ont respectivement M et N filtres, la couche convolutionnelle nécessitera $M \times N$ filtres pour effectuer l'opération de convolution. Chaque filtre est responsable de l'extraction de caractéristiques spécifiques, comme les bords, les textures, ou les motifs plus complexes, à différents niveaux de la hiérarchie des couches.

Les CNN sont particulièrement efficaces pour les tâches de vision par ordinateur telles que la classification d'images, la détection d'objets et la segmentation d'images, en raison de leur capacité à apprendre et à généraliser des caractéristiques spatiales locales tout en réduisant

le nombre de paramètres par rapport aux réseaux de neurones entièrement connectés. Les CNN peuvent également être appliqués à d'autres types de données structurées, comme les séquences temporelles ou les données audio, en adaptant la dimensionnalité des convolutions pour correspondre à la nature des données.




Figure III. 4 : Principe de fonctionnement d'une couche convolutionnelle.

III.7. PREDISTORSION NUMERIQUE BASE SUR LES RESEAUX DE NEURONES

La prédistorsion numérique basée sur les réseaux de neurones est une technique avancée utilisée pour corriger les distorsions non linéaires introduites par les amplificateurs de puissance dans les systèmes de communication. Contrairement aux méthodes traditionnelles de DPD qui utilisent des modèles mathématiques fixes, les réseaux de neurones offrent une approche adaptative et flexible. Grâce à leur capacité à apprendre et à modéliser des relations complexes, les réseaux de neurones peuvent capturer les caractéristiques non linéaires de l'amplificateur avec une précision élevée. Ils sont entraînés à partir de données d'entrée et de sortie de l'amplificateur, ce qui permet au réseau de prédire la correction nécessaire pour chaque signal. Cette prédiction est ensuite appliquée au signal d'entrée avant qu'il ne soit amplifié, compensant ainsi les distorsions et améliorant la linéarité et l'efficacité de la transmission. En raison de leur capacité à s'adapter à différents types de distorsions et à des conditions de fonctionnement variées, les réseaux de neurones rendent la DPD plus robuste et performante, répondant ainsi aux exigences des systèmes de communication modernes à haut débit.

III.7.1. RESEAU DE NEURONES POUR LA DPD AM/AM

Dans ce paragraphe, nous présentons l'architecture du réseau de neurones conçu pour inverser la caractéristique AM/AM de AP. Cette architecture est illustrée à la Figure III.5. Elle a été entièrement personnalisée pour répondre spécifiquement au problème de l'inversion de la caractéristique AM/AM de l'AP.




Figure III. 5 : DPD pour la distorsion AM/AM

Pour réduire la complexité computationnelle de ce modèle, nous proposons d'utiliser un seul neurone sigmoïde. Ce neurone est capable d'estimer la fonction inverse de manière efficace. Cependant, pour améliorer la précision de cette estimation, nous ajoutons une couche supplémentaire composée de fonctions ReLU (Rectified Linear Unit). Les fonctions ReLU sont bien connues pour leur capacité à introduire de la non-linéarité dans le modèle, ce qui aide à affiner l'estimation fournie par le neurone sigmoïde.

Dans cette configuration, le réseau prend l'amplitude de sortie de l'amplificateur de puissance comme entrée et prédit l'amplitude d'entrée correspondante. Cette approche permet de modéliser et de corriger les distorsions de manière efficace. Le réseau de neurones est optimisé pour approximer la fonction inverse de la caractéristique AM/AM, ce qui est essentiel pour obtenir une linéarisation précise de l'AP.

Il est important de noter que, conformément au corollaire (II.3), la fonction inverse doit être bijective. Cela signifie qu'à chaque sortie correspond une entrée unique, et vice-versa, ce qui est crucial pour assurer une linéarisation efficace.

La fonction inverse est définie comme une combinaison de fonctions. La première partie de cette combinaison modélise l'inverse de la caractéristique AM/AM et est spécifiquement conçue pour corriger les non-linéarités tout en conservant la zone linéaire de l'amplificateur. La deuxième partie de la combinaison, utilisant également des fonctions ReLU, affine cette

correction en apportant des ajustements fins. Cela permet d'obtenir une prédistorsion numérique plus précise et efficace, améliorant ainsi les performances globales du système.

III.7.2. RESEAU NEURONAL POUR LA DPD AM/PM

Dans cette section, nous détaillons l'architecture du réseau neuronal utilisée pour corriger la distorsion de phase induite par l'amplificateur de puissance figure III.6. Contrairement à la distorsion AM/AM, qui concerne l'amplitude du signal, la distorsion AM/PM affecte la phase du signal. Pour corriger cette distorsion, notre approche repose sur l'utilisation d'un réseau neuronal spécialisé.




Figure III. 6 : DPD pour la distorsion AM/PM

L'architecture de ce réseau neuronal a été conçue en tenant compte de la complexité de la distorsion de phase et de la nécessité d'estimer précisément son opposé. Contrairement à la méthode utilisée pour inverser la caractéristique AM/AM, qui nécessite une estimation précise de la fonction inverse, notre objectif ici est de prédire l'opposé du décalage de phase.

Pour réduire la complexité computationnelle de notre modèle, nous avons opté pour une approche plus directe. Le réseau neuronal prend l'amplitude du signal en entrée et prédit directement l'opposé du décalage de phase. Cela nécessite moins d'opérations et permet une correction plus efficace de la distorsion de phase.

L'architecture du réseau neuronal comprend plusieurs couches, chaque couche étant conçue pour capturer différents aspects de la distorsion de phase. Une combinaison de fonctions d'activation telles que la sigmoïde et ReLU est utilisée pour modéliser la distorsion de manière précise et flexible.

De plus, le réseau neuronal est optimisé pour trouver la fonction qui, lorsqu'elle est appliquée à l'amplitude du signal, produit l'opposé du décalage de phase. Cette optimisation est réalisée pendant la phase d'apprentissage à l'aide de données d'entrée et de sortie fournies par l'amplificateur de puissance.

En résumé, notre approche basée sur un réseau neuronal offre une solution efficace pour corriger la distorsion de phase dans les systèmes de communication. En utilisant une architecture adaptée et en optimisant le réseau pour prédire l'opposé du décalage de phase, nous parvenons à réduire la complexité tout en améliorant la précision de la correction de la distorsion.

III.8. CONCLUSION

Dans ce chapitre, nous avons exploré le potentiel des réseaux de neurones dans le domaine de la linéarisation des amplificateurs de puissance. En examinant les neurones, les réseaux de neurones, et les différentes techniques d'apprentissage associées, nous avons mis en lumière l'importance cruciale du choix d'une architecture adaptée dans le cadre de la linéarisation par prédistorsion. Nous avons également examiné les modèles de réseaux de neurones et leur application dans la prédistorsion numérique. Ce chapitre nous a fourni une compréhension approfondie des concepts théoriques sous-jacents, nous préparant ainsi à passer à la pratique dans le prochain chapitre de notre mémoire.

CHAPITRE 4 : DPD BASEE SUR LES RESEAUX DE NEURONES POUR LA LINEARISATION D'UN AMPLIFICATEUR AVEC EFFET MEMOIRE.

IV.1. Introduction.....	45
IV.2. Système modèle.....	45
IV.3. Résultats et discussion	46
IV.4. Conclusion et perspectives	53

IV.1. INTRODUCTION

Ce chapitre présente la conception et la mise en œuvre d'une prédistorsion numérique basée sur les réseaux de neurones pour la linéarisation d'un amplificateur de puissance avec effet mémoire. Nous explorerons le développement d'un système modèle, suivie par l'analyse des résultats obtenus et une discussion sur leur pertinence. Enfin, ce chapitre se conclura par une synthèse des principales contributions de ce travail, ainsi que par des perspectives pour des recherches futures visant à améliorer davantage la performance et la robustesse de la prédistorsion numérique pour les amplificateurs de puissance.

IV.2. SYSTEME MODELE

On a opté dans le travail pour une prédistorsion numérique basée sur un réseau de neurones MLP Comme la montre la figure au-dessus, les couches cachées et la couche de sortie contiennent des neurones avec une architecture entièrement connectée c'est à dire que chaque entrée est connectée avec tous les neurones de la couche d'entrée. Pour les signaux complexes, généralement la couche d'entrée est de taille égale à deux (I et Q, parties réelles et parties imaginaires du signal d'entrée) et la même chose pour la couche de sortie (partie réelle et partie imaginaire du signal après prédistorsion). Les simulations ont prouvé qu'une seule couche cachée avec un nombre raisonnable de neurones peut donner une bonne prédistorsion. On a comme entrées les parties réelles $I_{in}(n)$ et les parties imaginaires $Q_{in}(n)$ du signal amplifié $z(n)$ à l'instant n et aux instants $(n-L)$ avec L est le retard. La fonction d'activation pour le 1^{ère} couche est une fonction non-linéaire qui est la tangente hyperbolique (*la relation entrée/sortie*) Et la fonction d'activation pour la couche de sortie est une fonction linéaire et l'algorithme « Gradient Descent backpropagation » (GD) est utilisé pour le calcul des poids w pour donner la partie réelle et la partie imaginaire du signal de la prédistorsion (fonction inverse) $\tilde{y}(n)$.




Figure IV. 1 : Schéma d'un Réseau MLP

IV.3. RESULTATS ET DISCUSSION

IV.3.1. PARAMETRES DE SIMULATION

Paramètre	Valeur numérique
Nombre de symbole (Nsymb)	2000
Ordre de modulation (M)	256
Input Back-Off (IBO)	8 dB
Tension de saturation (Vsat)	1
Alpha1	2
Beta1	1
Alpha2	4
Beta2	9
rapport signal sur bruit (EbN0dB)	0:2:20

Tableau IV. 1 : Paramètres de simulation.

Parmi les paramètres de simulation utilisés, le paramètre "bf" est spécifié comme étant égal à $[0.7692, 0.1538, 0.0769]$. Dans ce contexte, "bf" représente les coefficients d'un filtre à réponse impulsionnelle finie (FIR).

Dans cette étude, nous aborderons les changements de signal, les constellations et le BER (Bit Error Rate) dans le contexte de la DPD. Notre approche repose sur l'utilisation de réseaux de neurones pour améliorer la linéarité des amplificateurs de puissance. Avant d'appliquer la DPD, nous analyserons les caractéristiques du signal, les constellations et le BER. Ensuite, nous comparerons ces mesures avec celles obtenues après l'application de la DPD. Cette approche novatrice vise à optimiser les performances des amplificateurs tout en minimisant les distorsions.




Figure IV. 2: AM/AM du modèle d'Hammerstein

La figure IV.2 montre la relation AM/AM du modèle d'Hammerstein pour un amplificateur de puissance avec effet mémoire. Les points de données illustrent que, pour des valeurs croissantes de $z(n)$, $z(n)$ augmente de manière non linéaire, indiquant une distorsion non linéaire introduite par l'AP. Cette figure met en évidence l'effet mémoire et la non-linéarité de l'amplificateur de puissance avant l'application de toute technique de prédistorsion.




Figure IV. 3 : AM/AM du modèle d'Hammerstein après DPD

Cette figure illustre la relation AM/AM du modèle d'Hammerstein après l'application de la technique de NNDPD. Contrairement à la relation observée avant la DPD, les points de données montrent maintenant une augmentation linéaire de $y(n)$ en fonction de $x(n)$. Cette linéarité indique que la NNDPD a été efficace pour compenser les distorsions non linéaires initialement présentes dans l'amplificateur de puissance.

Pour atteindre cette linéarisation, nous avons utilisé la fonction inverse représentée dans la figure IV.4. Cette fonction inverse est appliquée au signal d'entrée pour générer un signal prédistorsionné qui compense les non-linéarités de l'AP. En appliquant cette fonction inverse, nous avons réussi à corriger les distorsions et à obtenir un signal de sortie linéaire après la NNDPD.




Figure IV.4 : Fonction inverse AM/AM de la DPD




Figure IV.5 : AM/PM du modèle d'Hammerstein

La figure illustre la relation AM/PM du modèle d'Hammerstein pour un amplificateur de puissance avec effet mémoire, avant la linéarisation. Les points de données montrent comment la phase du signal de sortie varie en fonction de l'amplitude du signal d'entrée. On observe une variation non linéaire de la phase, indiquant une distorsion de phase introduite par l'AP. Cette non-linéarité de phase nécessite une correction pour améliorer la performance globale du système de communication.




Figure IV.6 : AM/PM du modèle d'Hammerstein après DPD

Cette figure illustre la relation AM/PM du modèle d'Hammerstein pour un amplificateur de puissance après l'application de la DPD. Contrairement à la relation observée avant la linéarisation, les points de données montrent désormais une relation beaucoup plus stable et linéaire entre l'amplitude du signal d'entrée et la phase du signal de sortie. Cette amélioration indique que la DPD a été efficace pour compenser les distorsions de phase.

Pour atteindre cette linéarité de phase, nous avons utilisé une fonction inverse représentée dans la figure IV.7. Cette fonction inverse a été appliquée au signal d'entrée pour générer un signal prédistorsionné qui compense les non-linéarités de phase de l'AP. Grâce à l'application de cette fonction inverse, les distorsions de phase ont été corrigées, permettant d'obtenir un signal de sortie linéaire, comme illustré dans la figure IV.6.




Figure IV.7 : Fonction inverse AM/PM de la DPD




Figure IV.8 : Constellation sans DPD

La figure IV.8 représente une constellation des symboles émis complexes avant la NNDPD. On peut remarquer que la constellation semble former une sorte de carré décalé. Les points rouges sont dispersés de manière à décrire un motif global qui rappelle une structure quadrillée, mais avec des déviations et des déplacements par rapport à un carré parfait. Ces décalages sont typiques des distorsions et des effets non linéaires associés au modèle d'Hammerstein, indiquant que les symboles ne sont pas alignés sur une grille régulière. Cette irrégularité renforce la nécessité de la linéarisation pour corriger ces erreurs et obtenir une constellation régulière.




Figure IV.9 : Constellation après DPD

Une fois la technique de DPD appliquée, la figure IV.9 de la constellation subit une métamorphose significative. Les points complexes, qui étaient auparavant dispersés de manière irrégulière, se regroupent désormais de manière plus ordonnée et cohérente. La constellation prend une forme plus définie, avec des points alignés de manière plus précise, reflétant l'efficacité de la NNDPD pour corriger les distorsions non linéaires.




Figure IV.10 : Taux d'erreur binaire BER

La figure IV.10 montre la comparaison du taux d'erreur binaire pour un amplificateur de puissance de type Hammerstein avant et après l'application de notre solution NNDPD basée sur les réseaux de neurones.

La courbe rouge représente le BER de l'AP Hammerstein sans NNDPD. On observe que le BER reste élevé sur tout l'intervalle du E_b/N_0 , indiquant une mauvaise performance en termes de linéarisation. La courbe en bleu représente le BER de l'AP Hammerstein avec NNDPD. Cette courbe commence à des valeurs similaires à celles de la courbe rouge, mais commence à diminuer plus rapidement à partir de $E_b/N_0=10$ dB, atteignant des valeurs de l'ordre du $BER= 3.10^{-3}$, montrant une amélioration significative et prouvant l'efficacité de la NNDPD.

Cette comparaison illustre clairement l'efficacité de la NNDPD pour réduire le BER et améliorer la performance globale du système de communication.

IV.4. CONCLUSION ET PERSPECTIVES

Dans ce dernier chapitre, nous avons étudié l'efficacité de la NNDPD basée sur les réseaux de neurones pour la linéarisation d'un amplificateur présentant un effet mémoire. Les résultats obtenus ont montré une amélioration significative de la linéarisation tant pour l'AM/AM que pour l'AM/PM. De plus, l'analyse du taux d'erreur binaire a souligné l'efficacité

de notre technique de linéarisation, avec une réduction notable des erreurs de transmission. Les NNDPD a aussi corrigé la rotation et les distorsions dans la constellation après amplification.

Ces résultats prometteurs ouvrent la voie à plusieurs perspectives intéressantes pour de futures recherches. Par exemple, il serait bénéfique d'explorer davantage les applications pratiques de notre méthode de linéarisation dans des systèmes de communication réels. De plus, l'optimisation et l'adaptation continue de notre algorithme de NNDPD pourraient permettre d'améliorer encore davantage la qualité du signal et d'élargir ses applications potentielles dans divers contextes industriels. Parmi les autres perspectives, on pourrait augmenter la profondeur de mémoire de notre modèle pour mieux capturer les effets de mémoire complexes. L'utilisation de la modulation OFDM pourrait également être explorée pour vérifier la robustesse de notre méthode dans des scénarios de transmission plus exigeants. Enfin, tester d'autres modèles de réseaux de neurones pourrait offrir des améliorations supplémentaires et ouvrir de nouvelles opportunités d'optimisation.

CONCLUSION GENERALE

CONCLUSION GENERALE

Ce travail a exploré l'utilisation de la prédistorsion numérique basée sur les réseaux de neurones pour la linéarisation des amplificateurs de puissance avec effet mémoire dans les réseaux de télécommunications. L'objectif principal de cette étude était de développer une méthode efficace pour corriger les distorsions non linéaires et l'effet mémoire des amplificateurs de puissance afin d'améliorer la qualité et l'efficacité des signaux transmis.

Les résultats obtenus montrent que l'approche de prédistorsion numérique basée sur l'intelligence artificielle offre des améliorations significatives en matière de linéarisation des distorsions AM/AM et AM/PM. Les tests effectués ont démontré une réduction notable du taux d'erreur binaire, soulignant l'efficacité de notre programme de linéarisation. Ces performances renforcent la pertinence de l'application des réseaux de neurones dans le contexte de la prédistorsion numérique pour les systèmes de communication modernes.

En résumé, ce travail contribue de manière substantielle à l'optimisation des performances des réseaux de télécommunications en proposant une solution novatrice pour surmonter les limitations des amplificateurs de puissance non linéaires. L'intégration des réseaux de neurones pour la prédistorsion numérique se révèle être une approche prometteuse, ouvrant de nouvelles perspectives pour l'amélioration continue des systèmes de télécommunications.

Pour l'avenir, plusieurs axes de recherche pourraient être envisagés. D'une part, il serait pertinent de tester cette approche dans des environnements de communication réels pour valider son efficacité pratique. D'autre part, l'optimisation continue des algorithmes de réseaux de neurones et leur adaptation à des configurations matérielles variées pourraient encore améliorer les performances globales des systèmes de communication.

En conclusion, cette étude a démontré le potentiel des techniques d'intelligence artificielle pour améliorer les infrastructures de télécommunications, contribuant ainsi à une meilleure connectivité et à une qualité de service accrue pour les utilisateurs finaux.

BIBLIOGRAPHIE

- [1] **Kimon Vivien.** « Linearity and Efficiency of Load Modulated Power Amplifiers. Electronics ». *Université Paris-Est, 2020.*
- [2] **Basel Rihawi.** « Etude de l'amplification non linéaire de signaux MIMO pour les terminaux radio-mobiles. Traitement du signal et de l'image ». *Université Rennes 1, 2008.*
- [3] **Alexis Falempin.** « Adaptive Pre-Distortion for Power Amplifier Linearization based on Neural Networks ». *Signal and Image processing. Université Grenoble Alpes 2022.*
- [4] **NOBERT, Gabriel.** « Caractérisation et linéarisation d'amplificateur de puissance RF par prédistorsion numérique dans un contexte d'appareils mobiles ». 2017. *Thèse de doctorat. École de technologie supérieure.*
- [5] **Rafik Zayani.** « Pré-distorsion adaptative des non-linéarités HPA dans un système OFDM à l'aide des réseaux de neurones ». *Sciences de l'ingénieur ENIT, 2009.*
- [6] **Blaise Mulliez.** « Linéarisation à base de réseaux de neurones pour amplificateurs de puissance ». *Toulouse, 2015. Français.*
- [7] **Siqi Wang.** « Study on complexity reduction of digital predistortion for power amplifier linearization ». *Electronics. Université Paris-Est, 2018.*
- [8] **F. H. Raab et al** « Power amplifiers and transmitters for RF and microwave » in *IEEE Transactions on Microwave Theory and Techniques, March 2002*
- [9] **H. S. Black,** « Inventing the negative feedback amplifier: Six years of persistent search helped the author conceive the idea “in a flash” aboard the old Lackawanna Ferry » in *IEEE Spectrum, Dec. 1977*
- [10] **Amadou Mbaye.** « Linéarisation des amplificateurs de puissance large-bande pour des applications de communications tactiques et de diffusion audio ou vidéo numérique ». *Electronique. Université Paris-Est, 2015.*
- [11] **A. Katz, J. Wood and D. Chokola,** « The Evolution of PA Linearization: From Classic Feedforward and Feedback Through Analog and Digital Predistortion » in *IEEE Microwave Magazine (2016).*

- [12] **Hamoud, H. E.** « Linéarisation par pré-distorsion numérique d'amplificateurs de puissance pour les nouvelles générations des systèmes de télécommunications » *Doctoral dissertation, Limoges (2019)*.
- [13] **Cripps, S. C.** « RF power amplifiers for wireless communications ». *Norwood: Artech house (2006)*.
- [14] **J. Li and J. Ilow,** « A least-squares Volterra predistorter for compensation of non-linear effects with memory in OFDM transmitters, » *3rd Annual Communication Networks and Services Research Conference, Halifax, NS, Canada, (2005)*
- [15] **Gatet, L., Tap-Bêteille, H., & Lescure, M.** « Analog neural network design for real-time surface detection with a laser rangefinder. » *IEEE*. (2007, May)
- [16] **Mulliez, B., Moutaye, E., Tap, H., Gatet, L., & Gizard, F.** « Predistortion system implementation based on analog neural networks for linearizing high power amplifiers transfer characteristics ». *IEEE* (2013, July).
- [17] **Zhang, C., Patras, P., & Haddadi, H.** « Deep learning in mobile and wireless networking: A survey ». *IEEE Communications surveys & tutorials*, (2019).
- [18] **Tchamba Kuinze, B. S.** « Comparaison de l'efficacité du deep learning et de l'apprentissage automatique classique pour la reconnaissance d'activités humaine dans les habitats intelligents » *Doctoral dissertation, Université du Québec à Chicoutimi (2024)*.

RESUME

L'essor des télécommunications exige des transmissions de données à haut débit avec une qualité irréprochable. Les amplificateurs de puissance (APs), essentiels mais sujets à des non-linéarités près de leur zone de saturation, posent des défis majeurs. Ce mémoire propose une prédistorsion numérique basée sur l'intelligence artificielle (NNDPD) pour corriger ces distorsions. Nos résultats montrent une amélioration significative de la linéarisation des APs, une réduction du taux d'erreur binaire, et une bonne correction de la constellation, démontrant l'efficacité de notre approche pour optimiser les performances des réseaux de télécommunications.

Mots clés: Amplificateur de puissance, Pré-distorsion numérique, Efficacité énergétique, Réseaux de neurone.

ABSTRACT

The growth of telecommunications necessitates high-speed data transmissions with impeccable quality. Power amplifiers (PAs), crucial yet susceptible to nonlinearities near their saturation zone, present significant challenges. This paper proposes an Artificial Intelligence-based digital pre-distortion (AI-DPD) to rectify these distortions. Our findings demonstrate a noteworthy enhancement in PA linearization, a decrease in bit error rate, and proficient constellation correction, affirming the efficacy of our approach in optimizing telecommunication network performance.

Keywords: Power amplifier, Digital predistortion, Energy efficiency, Neural networks.

الملخص

تطلب ازدهار الاتصالات عمليات نقل بيانات عالية السرعة بجودة ممتازة. تمثل المضخمات تحديات كبيرة وهي مكونة أساسية لكنها عرضة للتشوهات غير الخطية بالقرب من منطقة التشبع الخاصة بها، يقترح هذا البحث نظام التشويه الرقمي المسبق المعتمد على الذكاء الاصطناعي لتسوية هذه التشوهات. تظهر نتائجنا تحسناً كبيراً في تسوية المضخمات، وتقليل معدل خطأ البت، وتعزيز جودة تشكيلات الإشارة، مما يثبت فعالية نهجنا في تحسين أداء شبكات الاتصالات

الكلمات الرئيسية: مكبر الطاقة، التحريف الرقمي المسبق، كفاءة الطاقة، الشبكات العصبية