

الجمهورية الجزائرية الديمقراطية الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة أبي بكر بلكايد - تلمسان

Université Aboubakr Belkaïd– Tlemcen –

Faculté de TECHNOLOGIE



MEMOIRE

MASTER en GENIE BIOMEDICAL

*Spécialité* : Imagerie Médicale

**Par** : Haouaia Amina & Adnane Nour El Houda Ahlem

**Sujet**

**Approche de reconstruction d'images IRM parallèle**

**Régularisé**

Soutenu publiquement, le 14 / 06 / 2023 , devant le jury composé de :

Mr. Hadj Slimane Zine Eddine	Professeur/	Univ. Tlemcen	Président
Mme. Iles Amel	MCA	Univ. Tlemcen	Directeur
Melle. Bekki Amane	Doctorante	Univ. Tlemcen	Co-Directeur de mémoire
Mme. Feroui Amel	MCA	Univ. Tlemcen	Examineur 1

Année Universitaire : 2022/2023

## *Remerciements*

*Nous exprimons notre gratitude envers Dieu pour nous avoir accordé la volonté et le courage de terminer nos études.*

*Nous souhaitons également exprimer notre profonde gratitude envers nos parents, HAOUAIJA et ADNANE, pour le soutien inconditionnel qu'ils nous ont apporté tout au long de cette période.*

*Nous sommes reconnaissants envers Mme KORTI AMEL et Mlle BEKKI AMANE pour leur patience et leur intérêt tout au long de ce travail. Leurs conseils précieux, leurs remarques constructives et leurs idées novatrices ont grandement contribué à la réussite de cette étude.*

*Nous tenons à exprimer notre profonde gratitude envers les membres du jury, Monsieur Hadj Slimane Zine Eddine et Madame Feroui Amel, et nous sommes honorés par leur présence lors de la discussion. Nous attendons avec impatience leur évaluation constructive, qui ne manquera pas de contribuer grandement à l'enrichissement de notre travail.*

*Enfin, nous remercions tous les enseignants qui nous suivent le long de nos études et tous ceux qui ont participé de près ou de loin à l'élaboration de ce travail*



*Au nom d'ALLAH le très miséricordieux  
En premier lieu, je rends grâce à ALLAH qui a  
illuminé ma voie pour atteindre ce moment tant  
attendu*

*Je souhaite exprimer tout mon amour et mon  
respect à mes chers parents, Hamza et Fatima, et  
je prie DIEU de les préserver et de les protéger,  
INCHAA ALLAH.*

*Je dédie humblement mon travail à ma chère  
sœur Houaria, ainsi qu'à mes chers frères Nadjadi  
et Abde illah.*

*Je tiens également à adresser mes remerciements à  
toute la famille Adnane et la famille Derdiri, ainsi  
qu'à tous mes collègues et à toutes les personnes  
qui me connaissent.*

*À mon binôme Amina qui a été toujours active et  
très sympathique avec moi.*

*À ma chère amie Sarah elle a toujours été là  
pour moi.*

**AHEM NOUR EL HOUDA**





*Avec l'aide d'ALLAH je termine ce travail  
que je dédie :*

*À mes chers parents HAOUAIJA pour leur  
confiance ,leur amour, leur soutien, leurs  
sacrifices et toutes les valeurs qu'ils ont su  
m'inculquer.*

*À ma sœur Fatima Zohra ainsi pour sa  
tendresse et*

*ses encouragements, qu'à mon frère  
Abderrahmane j'espère  
que la vie lui réserve le meilleur.*

*A toute la famille HAOUAIJA et la famille  
BOUALEM*

*A toutes mes amies en particulier ma chère  
Sarah , A Hamza Je tiens à lui exprimer ma  
sincère gratitude pour tout son soutien  
Mon chère binôme Ahlem qui a partagé avec  
moi les moments difficiles de ce travail, Je la  
remercie*

*Amína*



## Résumé :

L'imagerie parallèle est une technique avancée d'imagerie médicale qui a permis une amélioration significative de la qualité et de la rapidité de la reconstruction d'images IRM. La reconstruction GRAPPA est l'une des méthodes d'imagerie parallèle qui a démontré son efficacité dans les applications médicales. L'objectif de ce travail consiste à améliorer la reconstruction GRAPPA, qui bien qu'étant une méthode efficace, présente certaines limites en termes de qualité d'image. Pour résoudre ses problèmes, nous avons proposé de la rénover en se basant sur une méthode plus moderne et plus efficace, à savoir les réseaux de neurones convolutifs (CNN). Nous ont testé notre approche sur différents types de données. Les résultats obtenus ont prouvé que la reconstruction par notre approche offre des perspectives passionnantes pour l'amélioration de l'imagerie parallèle.

**Mots clés :** Imagerie parallèle, GRAPPA, l'apprentissage profond, les réseaux de neurones convolutifs, reconstruction d'image.

## Abstract :

Parallel imaging is an advanced medical imaging technique that has allowed for significant improvements in the quality and speed of MRI image reconstruction. GRAPPA reconstruction is one of the parallel imaging methods that have demonstrated its effectiveness in medical applications. The objective of this work is to enhance GRAPPA reconstruction, which, despite being an efficient method, has certain limitations in terms of image quality. To address these issues, we propose to renovate it by leveraging a more modern and effective method, namely convolutional neural networks (CNNs). We have tested our approach on different types of data, and the results have shown that reconstruction using our approach offers exciting prospects for improving parallel imaging.

**Keywords:** Parallel imaging, GRAPPA, deep learning, convolutional neural networks, image reconstruction.

## ملخص :

التصوير الموازي هو تقنية متقدمة في التصوير الطبي التي ساهمت في تحسين جودة وسرعة إعادة بناء صور الرنين المغناطيسي. إعادة البناء بواسطة GRAPPA هو احد الأساليب التصوير الموازي التي أثبتت فعاليتها في التطبيقات الطبية يهدف هذا العمل إلى تحسين إعادة بناء GRAPPA التي على الرغم من فعاليتها إلا أنها تعاني من بعض القيود فيما يتعلق بجودة الصور و لحل هذه المشاكل اقترحنا تحديثها باستخدام أسلوب أكثر حداثة وفعالية و هو الشبكات العصبية المتعمقة (CNN)، لقد اخترنا نهجنا على أنواع مختلفة من البيانات . أثبتت النتائج التي تم الحصول عليها أن إعادة البناء باستخدام نهجنا يوفر آفاقاً مثيرة لتحسين التصوير الموازي. **الكلمات الرئيسية:** التصوير الموازي، التعلم العميق، الشبكات العصبية المتعمقة، إعادة بناء الصور GRAPPA.

# SOMMAIRE

LISTES DES FIGURES.....	IX
LISTE DES TABLEAUX.....	XI
LISTE DES ABREVIATIONS ET SYMBOLES.....	XI
INTRODUCTION GENERALE .....	1
Chapitre I: Imagerie par résonance magnétique parallèle.....	2
1. Introduction .....	3
2. Appareillage IRM.....	3
2.1 Aimant.....	4
2.2. Bobines de gradient.....	5
2.3. Bobines radiofréquence (RF) .....	7
2.4. Blindages.....	8
3. Base physique de la RMN.....	9
3.1. Résonance magnétique nucléaire (RMN) .....	9
3.2. Phénomène de relaxation .....	10
4. Séquences utilisées en IRM.....	12
4.1. Écho de spin .....	12
4.2.Écho de gradient.....	13
5. Reconstruction d'image IRM .....	14
5.1. Sélection de coupe.....	14
5.2. Encodage de phase .....	15
5.3. Codage de fréquence .....	17
6. Espace k et formation d'image .....	17
7. Imagerie parallèle .....	20
7. 1. Antennes en réseau phasé.....	21

7.2. Méthodes de reconstruction .....	21
8. Conclusion .....	22
Chapitre II: Méthodes de reconstruction d'image      GRAPPA et DEEP LEARNING.....	23
1. Introduction .....	24
2. Reconstruction par la méthode GRAPPA .....	24
2.1 Détermination des poids dans GRAPPA.....	25
2.2 Processus de la méthode GRAPPA.....	26
3. Reconstruction par l'apprentissage profond .....	28
3.1 Apprentissage profond .....	28
3.2 Réseaux neuronaux convolutifs (CNN) .....	29
4. Etat de l'art .....	38
5. Conclusion .....	42
Chapitre III : Simulation numérique des méthodes de reconstruction d'image.....	43
1. Introduction .....	44
2. Données utilisées.....	44
3. Environnement de travail .....	45
3.1 Python.....	45
3.2 MATLAB .....	46
3.3 Matériel utilisé.....	46
4. Paramètres d'évaluations.....	47
4.1 Rapport signal sur bruit (PSNR) : .....	47
4.2 Erreur relative de la norme L 2 (RLNE) : .....	47
4.3 Indice de similarité structurelle moyen (MSSIM) : .....	47
5. Etude d'algorithmes de reconstruction.....	48
5.1 Algorithme de Grappa .....	48
5.2 Algorithme CNN .....	51
6. Algorithme proposé.....	56

6.1	Reconstruction de notre approche sur l'image fantôme .....	58
6.2	Reconstruction de notre approche sur des données réelles .....	58
7.	Développement d'une interface graphique .....	62
8.	Conclusion.....	64
CONCLUSION GENERALE .....		65
BIBLIOGRAPHIE .....		66

## LISTES DES FIGURES

N°	Figure	PAGE
<b>I-1</b>	Schéma de principe d'un appareil IRM	<b>4</b>
<b>I-2</b>	a) aimant à résistance, b) aimant supraconducteur, c) aimant permanent	<b>5</b>
<b>I-3</b>	Bobines de gradient selon l'axe Z	<b>6</b>
<b>I-4</b>	Bobines de gradient dans la direction de l'axe X	<b>6</b>
<b>I-5</b>	Bobines de gradient selon Y	<b>6</b>
<b>I-6</b>	Bobine radiofréquence	<b>8</b>
<b>I-7</b>	Blindage de champ magnétique	<b>9</b>
<b>I-8</b>	Signal RMN en fonction du temps	<b>10</b>
<b>I-9</b>	Schéma représente une vision newtonienne du spin	<b>11</b>
<b>I-10</b>	Relaxation longitudinale	<b>11</b>
<b>I-11</b>	Relaxation transversale	<b>12</b>
<b>I-12</b>	Séquence écho de spin.	<b>13</b>
<b>I-13</b>	Chronogramme des séquences écho de spin et écho de gradient	<b>14</b>
<b>I-14</b>	Sélection de coupe en IRM avec un gradient de champ magnétique en z pendant l'impulsion radiofréquence	<b>15</b>
<b>I-15</b>	Codage de phase.	<b>16</b>
<b>I-16</b>	Codage de fréquence et le signal RMN	<b>17</b>
<b>I-17</b>	Formation de l'image	<b>18</b>
<b>I-18</b>	Espace k (le contraste et résolution)	<b>18</b>
<b>I-19</b>	Acquisition simultanée de l'objet à l'aide par 8 antennes générant 8 images, une pour chaque canal	<b>21</b>
<b>II-1</b>	Schéma représente détermination des poids GRAPPA	<b>26</b>
<b>II-2</b>	Processus de la méthode GRAPPA	<b>27</b>
<b>II-3</b>	Sous branches de l'intelligence artificielle.	<b>28</b>
<b>II-4</b>	Exemple de pas de 2	<b>30</b>
<b>II-5</b>	Padding de 2 sur une matrice de taille 32×32	<b>31</b>
<b>II-6</b>	Processus de convolution	<b>31</b>
<b>II-7</b>	Processus de convolution	<b>32</b>
<b>II-8</b>	Fonctions d'activation.	<b>33</b>
<b>II-9</b>	a) Maxpooling, b) average Pooling	<b>34</b>

<b>II-10</b>	Schéma du CNN codeur-décodeur	<b>35</b>
<b>III-1</b>	Images correspondent aux données réelles (a) image brain_8ch (b) image brain_32ch, (c) brain_alias_8ch	<b>45</b>
<b>III-2</b>	Logo Python	<b>46</b>
<b>III-3</b>	Logo MATLAB	<b>46</b>
<b>III-4</b>	Organigramme de la méthode de reconstruction GRAPPA	<b>49</b>
<b>III-5</b>	Image originale de fantôme (a) et image reconstruite par la méthode GRAPPA (b)	<b>50</b>
<b>III-6</b>	(a) Image réelle de référence, (b) image reconstruite par la méthode GRAPPA	<b>51</b>
<b>III-7</b>	Organigramme de la méthode de reconstruction CNN	<b>52</b>
<b>III-8</b>	Image originale fantôme (a) et image reconstruite par la méthode CNN (b)	<b>53</b>
<b>III-9</b>	Résultats de reconstruction de données réelles obtenus suite au réglage du nombre d'époques.	<b>54</b>
<b>III-10</b>	(a) Image originale, (b) image reconstruite par la méthode CNN.	<b>55</b>
<b>III-11</b>	Organigramme d'algorithme proposé	<b>57</b>
<b>III-12</b>	a) Image fantôme originale, (b) image reconstruite par notre approche	<b>58</b>
<b>III-13</b>	Image originale réelle (a) et image reconstruite par notre approche (b)	<b>59</b>
<b>III-14</b>	(a) Image originale, (b) image reconstruire par la méthode GRAPPA, (c)image reconstruite par notre approche.	<b>60</b>
<b>III-15</b>	a) Image originale, (b) image reconstruire par la méthode GRAPPA, (c)image reconstruite par notre approche.	<b>61</b>
<b>III-16</b>	Interface d'accueil	<b>62</b>
<b>III-17</b>	Interface de reconstruction par GRAPPA.	<b>63</b>
<b>III-18</b>	Interface de reconstruction par CNN.	<b>63</b>
<b>III-19</b>	Interface de reconstruction par notre approche	<b>64</b>

## LISTE DES TABLEAUX

N°	Titre	Page
01	Paramètres d'évaluations obtenus d'image fantôme a partie la reconstruction GRAPPA	50
02	Paramètres d'évaluations obtenus d'image réelle a partir la reconstruction GRAPPA	51
03	Paramètres d'évaluations obtenus d'image fantôme a partie la reconstruction CNN	53
04	Paramètres d'évaluations obtenus d'image réelle a partir la reconstruction CNN	55
05	Paramètres d'évaluations obtenus d'image fantôme à partir de notre approche	58
06	Paramètres d'évaluations obtenus d'image réelle a partie notre approche	59
07	Paramètres d'évaluations obtenus d'image brain_8ch	60
08	Paramètres d'évaluations obtenus d'image brain_alias_8ch.	61

## LISTE DES ABREVIATIONS ET SYMBOLES

Symbole	ABREVIATIONS
<b>IRM</b>	Imagerie par Résonance Magnétique
<b>IRMP</b>	Imagerie par Résonance Magnétique parallèle
<b>B<sub>0</sub></b>	Champ magnétique statique d'intensité B <sub>0</sub>
<b>B<sub>1</sub></b>	Champ électromagnétique radio fréquence
<b>RMN</b>	Résonance magnétique nucléaire
<b>M<sub>0</sub></b>	Animation résultante M
<b>M</b>	Animation macroscopique
<b>M<sub>xy</sub></b>	Composante transversale
<b>M<sub>z</sub></b>	Composante longitudinale
<b>T<sub>1</sub></b>	Temps de relaxation longitudinale
<b>T<sub>2</sub></b>	Temps de relaxation transversale
<b>T*2</b>	Temps de relaxation transversale résultant
<b>TE</b>	Temps d'échos
<b>TR</b>	Temps de répétition
<b>FID</b>	Free Induction Decay
<b>FOV</b>	Field of View
<b>NPE</b>	Nombre de ligne de codage de phase
<b>SMASH</b>	Simultaneous Acquisition of Spatial Harmonics
<b>GRAPPA</b>	Generalized Autocalibrating Partially Parallel Acquisitions
<b>SENSE</b>	Sensitivity Encoding
<b>CNN</b>	Conventional neural network
<b>ACS</b>	Autocalibration signal
<b>RELU</b>	Rectified Linear Unit layer
<b>SPGR</b>	Séquence spoiled écho de gradient

## INTRODUCTION GENERALE

L'imagerie médicale est une branche importante de la médecine qui permet de visualiser l'intérieur du corps humain à des fins de diagnostic, de traitement et de recherche. L'imagerie par résonance magnétique (IRM) est une modalité d'imagerie médicale non invasive qui recourt à des champs magnétiques et des ondes radio pour obtenir des images détaillées des tissus mous et des organes internes du corps humain. Une avancée récente dans ce domaine est l'imagerie par résonance magnétique parallèle (IRMp), qui connaît un développement important. Plusieurs méthodes d'acquisition, telles que SENSE et GRAPPA, ont été développées en imagerie parallèle, notamment pour obtenir une imagerie de haute qualité plus rapidement que l'imagerie conventionnelle.

L'apprentissage profond, quant à lui, est une méthode d'apprentissage automatique qui utilise des réseaux de neurones profonds pour effectuer des tâches complexes telles que la classification, la segmentation et la détection d'objets dans les images. La combinaison de l'IRM parallèle et du deep learning offre des nouvelles perspectives pour améliorer l'imagerie médicale en offrant des méthodes plus précises et automatisées pour diagnostiquer les maladies.

Notre but principal était d'améliorer la reconstruction GRAPPA en raison de tous ses avantages par rapport aux autres méthodes de reconstruction. Nous avons examiné différentes méthodes dans le but de trouver celle qui convient le mieux. Nous sommes parvenus à trouver la méthode d'apprentissage profond. De ce fait, nous avons proposé à travers ce mémoire d'améliorer la reconstruction GRAPPA par la méthode d'apprentissage profond.

Notre mémoire est composé de trois chapitres, dont le premier présente brièvement les équipements et le principe de l'Imagerie par Résonance Magnétique (IRM), l'imagerie parallèle et les méthodes de reconstruction les plus couramment utilisées. Le deuxième chapitre présente en détail les méthodes de reconstruction GRAPPA et CNN, ainsi qu'un aperçu des travaux récents réalisés sur ces dernières afin de se tenir à jour.

Le dernier chapitre présente une étude détaillée sur les deux méthodes : GRAPPA et CNN, ainsi que notre approche en utilisant différents types de données et différents critères d'évaluation tels que PSNR, RLNE et MMSIM. Ce chapitre présente à la fin notre interface graphique spécialement conçu pour l'aide au diagnostic.

# **Chapitre I: Imagerie par résonance magnétique parallèle**

## 1. Introduction

L'imagerie par résonance magnétique (IRM) est une technique d'imagerie médicale très demandée par les médecins en raison de sa grande précision par rapport aux autres techniques d'imagerie médicale. Elle utilise exclusivement la réponse du noyau d'hydrogène, abondant dans le corps humain.

L'IRM "parallèle" est une nouvelle technique d'imagerie par résonance magnétique dont le terme « parallèle » vient du fait que les signaux sont acquis simultanément à partir de plusieurs bobines. Cela explique que les techniques d'IRM parallèles ont été mises au point afin d'accélérer l'acquisition des images. En imagerie parallèle, l'acquisition est accélérée selon le coefficient d'accélération choisi qui correspond aux sous-échantillonnages des données reçues à partir de multiples bobines.

Dans ce chapitre, nous allons fournir une brève introduction sur l'équipement IRM ainsi que le principe d'imagerie par résonance magnétique (IRM). Nous allons exposer à la fin l'imagerie parallèle et ses méthodes de reconstruction.

## 2. Appareillage IRM

Quatre composants essentiels représentent l'imageur IRM (voir figure (I-1)) :

L'aimant principal.

Les bobines de gradient.

Les bobines radio fréquence.

Le blindage.

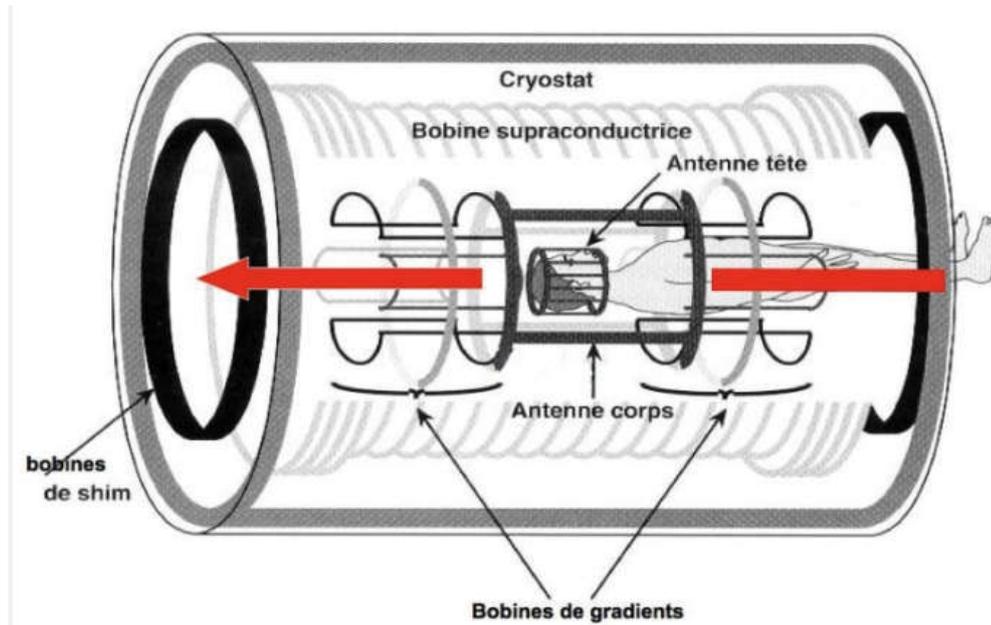


Figure I-1 : Appareillage IRM [1].

### 2.1 Aimant

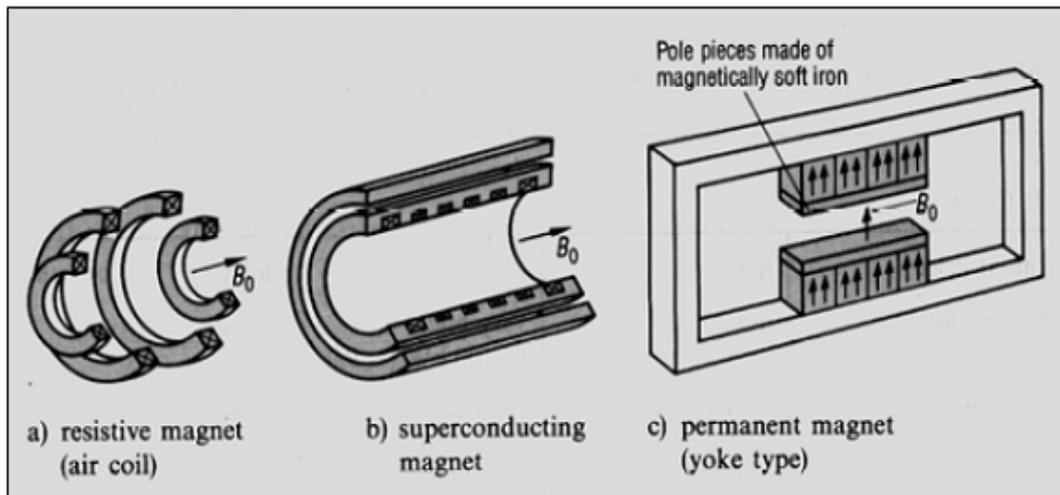
L'apparition de l'aimantation  $M$  en IRM est due à la présence d'un grand aimant qui est responsable à la création d'un champ magnétique intense  $B_0$  nécessaire à l'alignement des noyaux d'hydrogène [1].

Les caractéristiques de l'aimant jouent un rôle déterminant dans la qualité du champ magnétique, en ce qui concerne la [2] :

- Valeur et stabilité du champ magnétique [2].
- Type d'aimant utilisé (résistif, supraconducteur, permanent) [2].
- Caractéristiques physiques telles que le poids, la taille et le champ de fuite [2].
- Homogénéité du champ [2].

Actuellement, tous les fabricants optent pour un aimant supraconducteur car il présente les meilleures caractéristiques, permettant d'obtenir un champ magnétique extrêmement élevé [3].

La figure (I-2) représente les différents types d'aimants utilisés en IRM.



**Figure I-2:** a)aimant résistif, b) aimant supraconducteur, c) aimant permanent [41].

### 2 .2.Bobines de gradient

Les bobines de gradient permettent d'établir une relation entre la distance et la fréquence de résonance, qui est à l'origine de la formation de l'image [1]. Ces bobines génèrent un gradient de champ magnétique  $B_0$ .

Les gradients de champ magnétique sont indispensables pour le codage spatial du signal. Ils sont utilisés pour obtenir une variation linéaire de l'intensité du champ magnétique dans la direction de l'espace. Ce changement d'intensité s'ajoute au champ magnétique principal, il est généré par des paires de bobines placées dans chaque direction spatiale (x, y, z) [3].

La figure (I-3) représente les bobines du gradient du champ magnétique  $B_0$  appliqué selon l'axe Z.

# Chapitre I:Imagerie par résonance magnétique parallèle

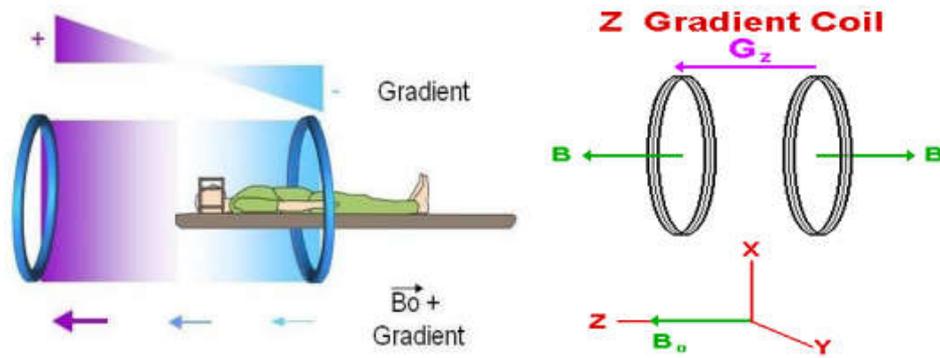


Figure I-1 : Bobines de gradient selon l'axe Z [3].

La figure (I-4) représente les bobines du gradient du champ magnétique B0 appliqué selon l'axe X.

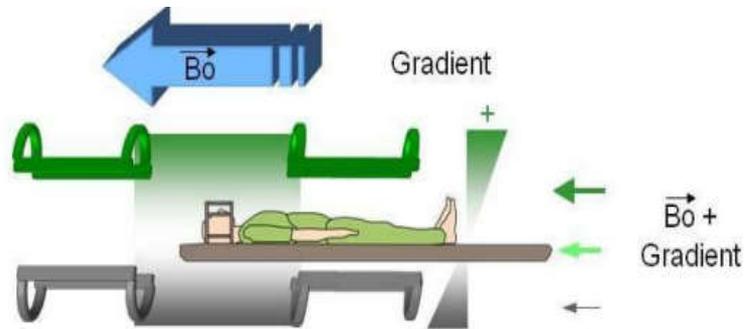


Figure I-2 : Bobines de gradient selon l'axe X [3].

La figure (I-5) représente les bobines du gradient du champ magnétique B0 appliqué selon l'axe Y.

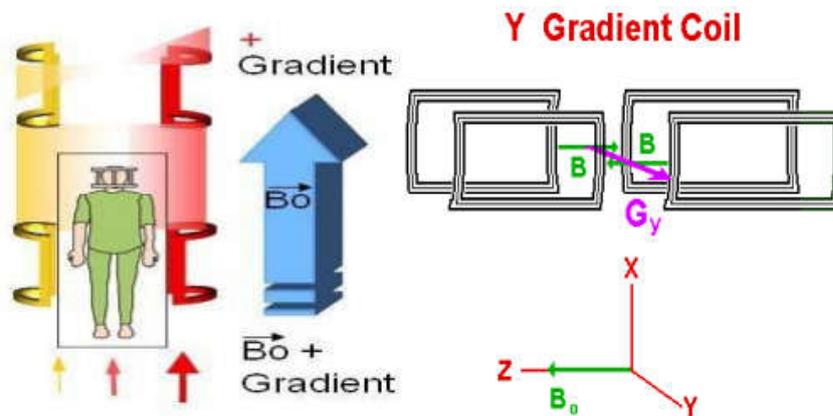


Figure I-3 : Bobines de gradient selon Y [3].

### 2.3. Bobines radiofréquence (RF)

Les bobines radiofréquence appelées aussi antennes jouent de rôles multiples et importants dans les équipements IRM. Ils produisent le champ magnétique radiofréquence  $B_1$  et reçoivent l'aimantation transversale.

Les bobines RF ont pour rôle initial de transformer un signal électrique émis par un émetteur de puissance radiofréquence en un champ magnétique rotatif, ce qui conduit à un basculement de l'aimantation nucléaire. Elles convertissent ensuite le champ radiofréquence engendré par la précession de l'aimantation nucléaire en un signal électrique, qui est acheminé vers le récepteur. Ce signal est finalement converti en données numériques par le récepteur et traité par la console d'imagerie [4].

Les bobines RF sont divisées en trois catégories :

**Les bobines d'émission-réception :** Ils sont utilisés pour transmettre des champs magnétiques et recevoir des signaux.

**Les bobines de transmission :** Ils sont utilisés pour générer des champs.

**Les bobines de réception :** Ils sont utilisés pour détecter les signaux de relaxation de spin dans le sujet imagé.

La figure (I-6) représente les antennes (bobines) radiofréquences les plus utilisées en IRM telles que l'antenne corps entier, l'antenne genou, l'antenne tête, l'antenne abdominale et l'antenne de la colonne vertébrale.

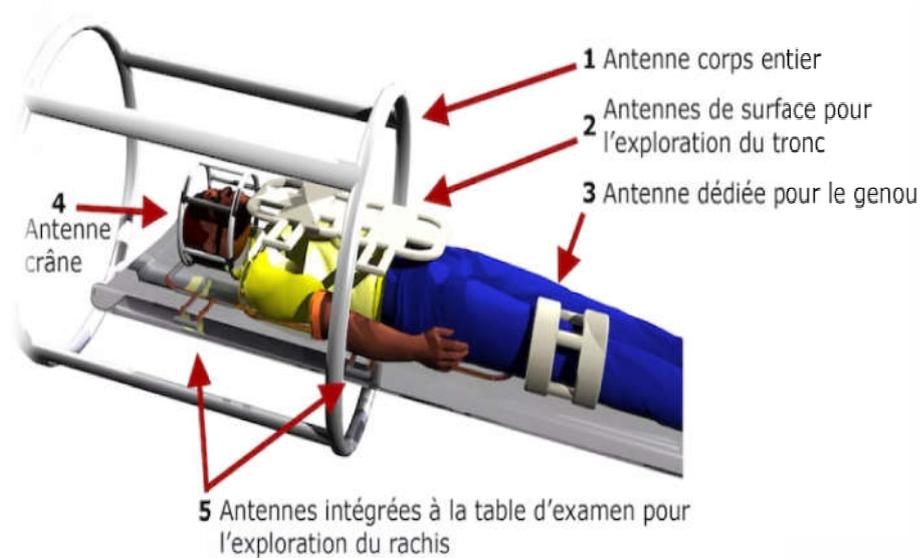


Figure I-4 : Bobines radiofréquence [4].

### 2.4. Blindages

En IRM, le blindage est destiné à contenir le champ magnétique généré par la machine et à l'isoler des champs extérieurs qui viendraient perturber l'acquisition. Il y a deux types de blindages dans une configuration IRM :

#### 2.4.1. Blindage des ondes radiofréquences :

Il est maintenu en place par une cage de Faraday. Les murs, le sol et le plafond de la salle d'examen sont recouverts de plaques de cuivre qui absorbent toutes les ondes électromagnétiques externes susceptibles de perturber les protons affectés par le champ magnétique principal.

D'autre part, ces plaques de cuivre empêchent également les ondes RF de "sortir" de la salle et d'interférer avec l'électronique à proximité, comme les consoles d'acquisition

#### 2.4.2. Blindage du champ magnétique :

Sa fonction est de rapprocher le plus possible la ligne de champ magnétique de l'aimant, notamment pour amener la ligne de 0,5mT à la salle d'examen.

Selon l'appareil IRM, il existe deux types de blindage :

**Un blindage passif :** il s'agit d'un ensemble de poutrelles d'acier ou de fer doux entourant l'aimant [5].

Un **blindage actif** : il est constitué d'un bobinage métallique inversé placé aux deux extrémités du bobinage du champ principal  $B_0$  (figure (I-7)) [5].

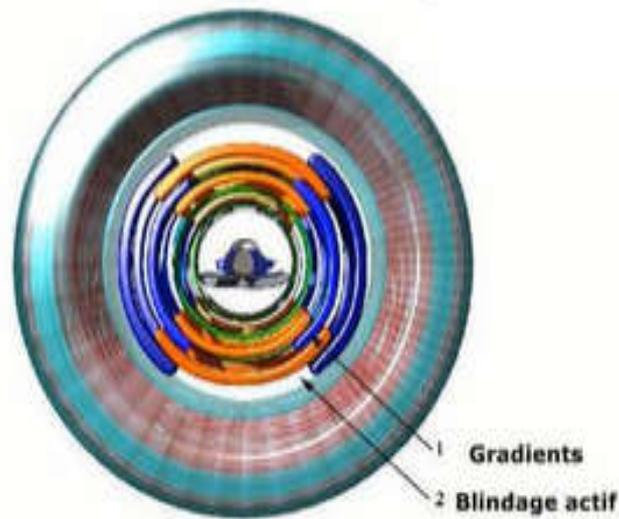


Figure I-5 : Blindage de champ magnétique [2].

Afin de comprendre le principe de fonctionnement des imageurs IRM, il est important de se familiariser avec les principes de base de la résonance magnétique nucléaire (RMN).

### 3. Base physique de la RMN

En IRM, la matrice de reconstruction ou proprement dit l'image reconstruite présente des pixels. Chaque pixel présente un signal RMN numérisé reçu après relaxation de l'aimantation ; l'aimantation présente la somme d'un ensemble de moments de spin.

#### 3.1. Résonance magnétique nucléaire (RMN)

En RMN, l'interaction entre les noyaux atomiques et le champ magnétique est quantifiée, et seules certaines fréquences (appelées fréquences de résonance ou de Larmor) permettent cette interaction. La fréquence de résonance dépend du type de noyau observé et de l'environnement chimique du noyau.

Le principe de la résonance magnétique nucléaire (RMN) repose sur la détection d'aimantation provenant des spins des noyaux atomiques. La figure (I-8) explique le phénomène RMN, elle représente la trajectoire d'aimantation à l'échelle macroscopique. En présence de champs magnétiques  $B_0$  (1) et  $B_1$  (3), l'aimantation (2) bascule vers le plan transversal et suit une trajectoire sphérique (5). L'aimantation se trouve dans le plan

transverse à la fréquence de Larmor (4). Lorsque le champ RF B1 est désactivé, l'aimantation (6) revient progressivement à sa valeur initiale (7) en suivant la trajectoire inverse, c'est le phénomène de relaxation [4].

Le retour à la normale produit une émission d'ondes électromagnétiques qui peut être détectée et utilisée pour mesurer le signal RMN [6].

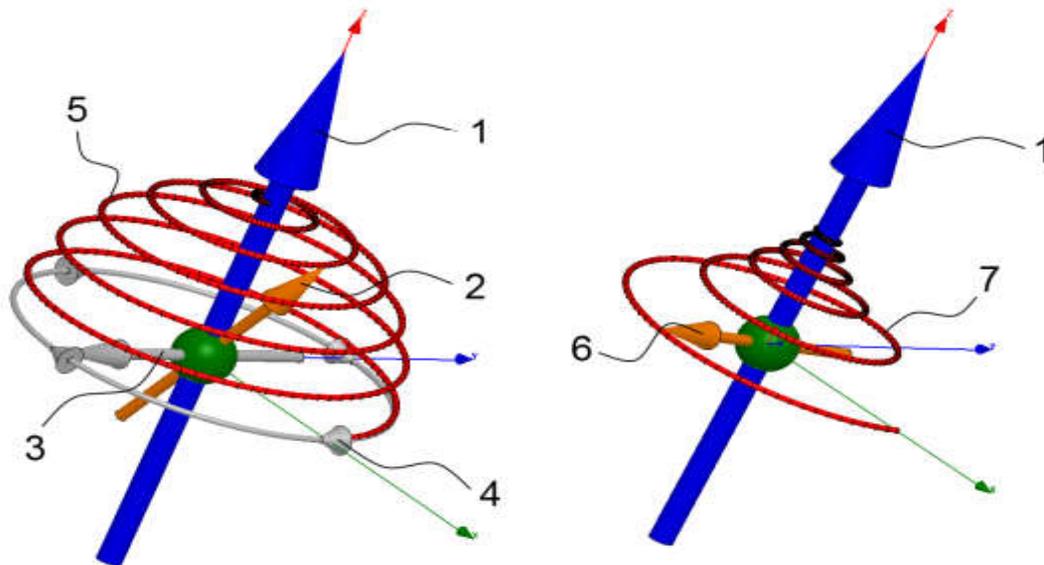


Figure I-8 : Trajectoires d'aimantation : basculement et relaxation [4].

### 3.2. Phénomène de relaxation

La relaxation est un phénomène qui se produit lorsque l'aimantation tissulaire revient à son état initial, ce qui produit une émission d'énergie sous forme d'ondes radiofréquences qui sont enregistrées lors d'une IRM. Il y a deux types de relaxation qui suivent des mécanismes différents: la relaxation longitudinale, qui régénère la composante longitudinale, et la relaxation transversale, qui diminue l'aimantation transversale [7].

#### 3.2.1. Relaxation longitudinale (spin- réseau) :

La relaxation longitudinale appelée aussi relaxation spin-réseau est basée sur un échange d'énergie thermique entre les protons et le réseau. Elle est mesurée par le temps de relaxation

T1 qui indique le temps nécessaire pour que l'aimantation longitudinale  $M_z$  revienne à sa valeur originale.

La figure (I-9) explique ce phénomène, l'aimantation longitudinale est initialement nulle puis elle augmente exponentiellement selon la fonction  $1-\exp(-t/T1)$ . Le temps T1 représente le délai nécessaire pour que la valeur de  $M_z$  atteigne 63% de sa valeur initiale. [8].

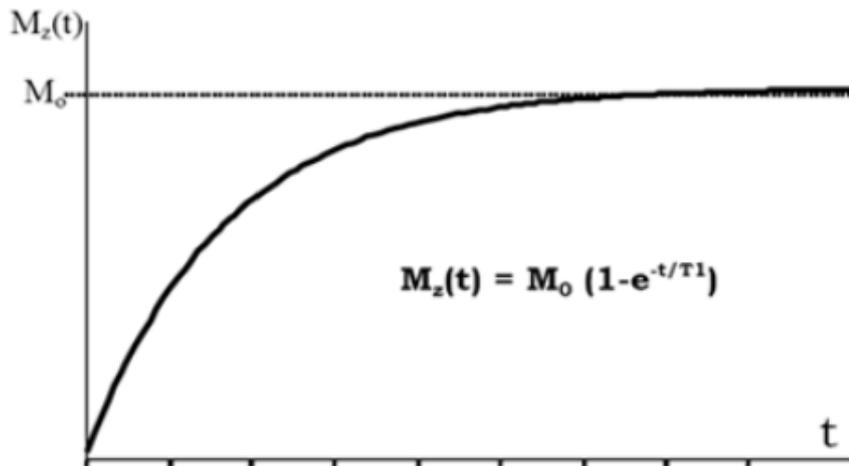


Figure I-9 : Relaxation longitudinale [8].

**3.2.2. Relaxation transversale (spin-spin) :**

La relaxation transversale est causée par l'interaction magnétique entre les spins, ce qui provoque un déphasage entre eux, entraînant une diminution exponentielle de l'aimantation transversale  $M_{xy}$  figure (I-10) [8].

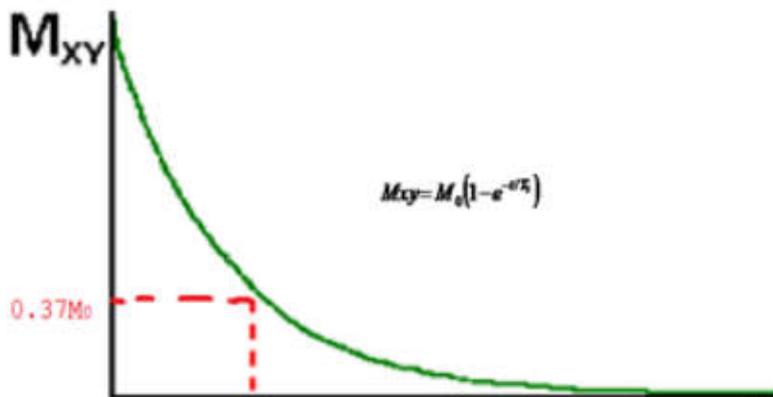


Figure I-10 : Relaxation transversale [8].

Le retour de l'aimantation à son état d'équilibre engendre un courant dans la bobine réceptrice produisant un signal appelé signal de précession ou FID en anglais (Free Induction Decay). Le signal FID est un sinusoïdal amorti d'une exponentielle (figure (I-11)).

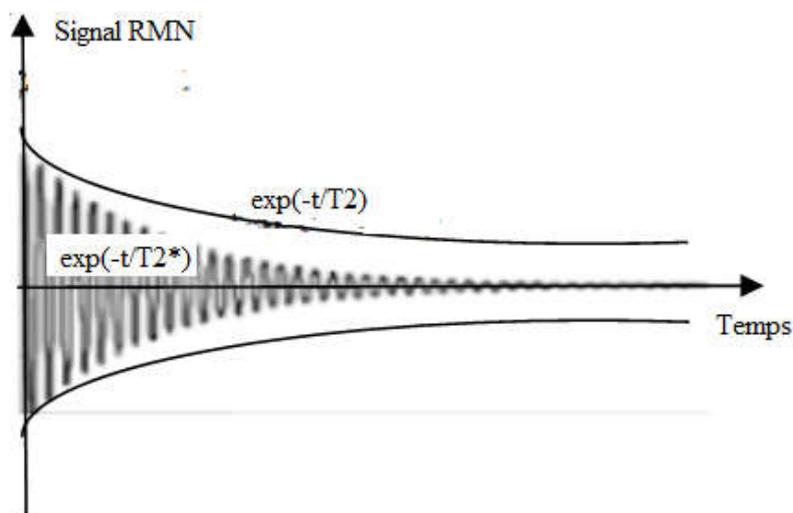


Figure I-11 : Signal RMN en fonction du temps [4].

Pendant l'acquisition des images IRM, plusieurs séquences peuvent être sélectionnées selon le besoin des manipulateurs.

### 4. Séquences utilisées en IRM

Les séquences d'IRM peuvent être divisées en deux grandes catégories en fonction du type d'écho détecté :

- ✓ Les séquences d'écho de spin
- ✓ Les séquences d'écho de gradient.

#### 4.1. Écho de spin

Les séquences d'écho de spin sont fondamentales en IRM, car elles permettent de produire des images pondérées en T1, T2 et en densité de protons. La séquence d'écho de spin se compose de deux impulsions successives : une impulsion d'excitation qui incline les spins de  $90^\circ$ , suivie d'une impulsion de rephasage de  $180^\circ$  appliquée à un temps  $TE/2$  (voir la figure (I-12)). Cette séquence est répétée à chaque intervalle de temps TR (temps de répétition).

**Temps d'écho (TE):** correspond à la durée entre l'onde RF d'excitation et le temps de lecture.

**Temps de répétition (TR):** représente le temps écoulé entre deux impulsions excitatrices successives de  $90^\circ$ .

À chaque fois que la séquence est répétée, une ligne de l'image IRM est créée en utilisant des codages de phase différents [8].

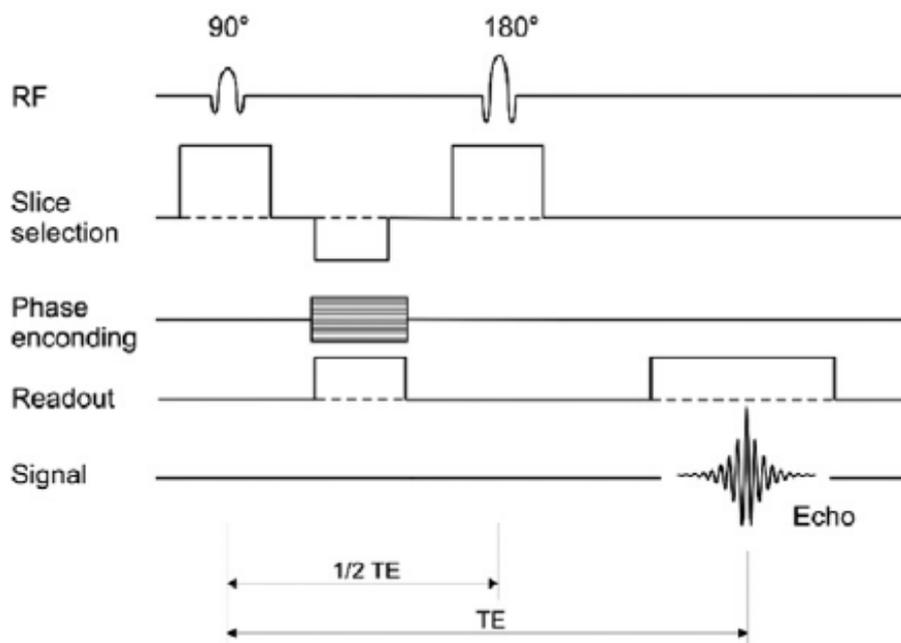


Figure I-12 : Séquence écho de spin.

La qualité de l'image RMN dépend principalement du temps de répétition TR, qui doit être choisi de manière à trouver le meilleur compromis entre une bonne résolution, une qualité d'image satisfaisante et le temps d'acquisition le plus court possible.

### 4.2.Écho de gradient

Cette séquence permet une acquisition d'images rapide par rapport à la séquence écho de spin, elle ne comporte pas une deuxième impulsion  $\pi$  ( $180^\circ$ ), ce qui limite l'angle de basculement du vecteur d'aimantation macroscopique à moins de  $90^\circ$  (la figure (I-13)). Les échos de gradient sont produits en appliquant un gradient bipolaire de lecture dans la direction codée en fréquence. Le premier lobe de gradient accélère le déphasage de l'aimantation transversale, tandis que le second anti-lobe rephase les spins [8].

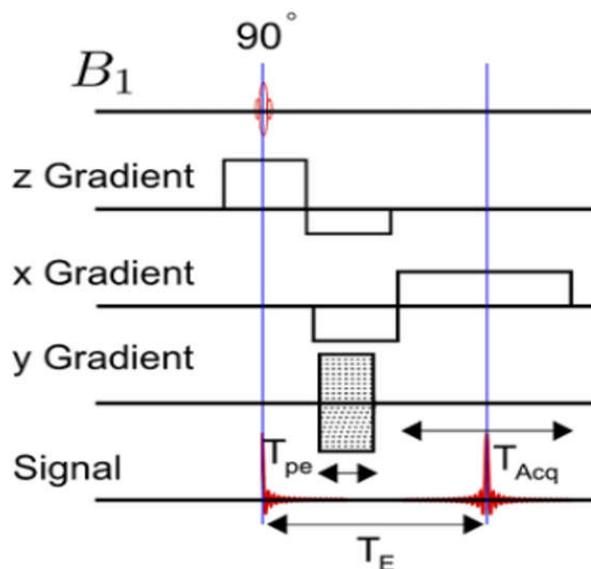


Figure I-13 : Séquence écho de gradient [42].

Après avoir compris le principe de fonctionnement de l'IRM, nous pouvons passer à l'étape la plus importante qui présente la reconstruction d'image.

## 5. Reconstruction d'image IRM

Afin d'obtenir une image IRM, le signal d'écho doit être localisé et codé spatialement en tout point de l'image. La localisation spatiale du signal repose sur deux notions fondamentales :

- L'utilisation d'un outil physique : les gradients de champs magnétiques.
- L'utilisation d'un outil mathématique : la transformée de Fourier [9].

Pour réaliser une image de coupe (2D) en IRM, l'encodage spatial est utilisé. Il exprime la sélection de coupe, le gradient d'encodage de phase et de fréquence. L'encodage spatial nécessite l'utilisation du gradient de champ magnétique, appliqués le long des axes x, y et z pour lesquels les gradients sont notés respectivement  $G_x$ ,  $G_y$  et  $G_z$ . Par conséquent, l'amplitude du champ magnétique varie régulièrement le long de l'axe d'application du gradient.

### 5.1. Sélection de coupe

Afin de sélectionner une coupe spécifique en IRM, il est nécessaire d'ajuster la fréquence de rotation des protons de manière à ce qu'ils puissent être excités par une onde radiofréquence de la même fréquence (résonance). Pour cela, il est essentiel d'appliquer simultanément un gradient de champ magnétique de sélection de coupe (GS) ainsi que des impulsions de radiofréquence d'excitation dans une direction spécifique [10].

Si on applique un gradient de champ magnétique  $G_z$  dans la direction  $z$ , la fréquence de Larmor du signal est calculée par :

$$f(z) = f_0 + \frac{\gamma}{2\pi} z \cdot G_z \quad (\text{I.1})$$

Avec :

$f(z)$  : la fréquence de Larmor dépendante de la position  $z$ .

$f_0$  : la fréquence de Larmor de référence.

$\gamma$  : le rapport gyromagnétique.

$z$  : la position le long de l'axe  $z$ .

$G_z$  : le gradient de champ magnétique appliqué selon l'axe  $z$ .

La Figure I-14 représente un exemple de sélection de coupe à travers le patient en appliquant simultanément l'impulsion radiofréquence et le gradient de champ magnétique le long de l'axe.

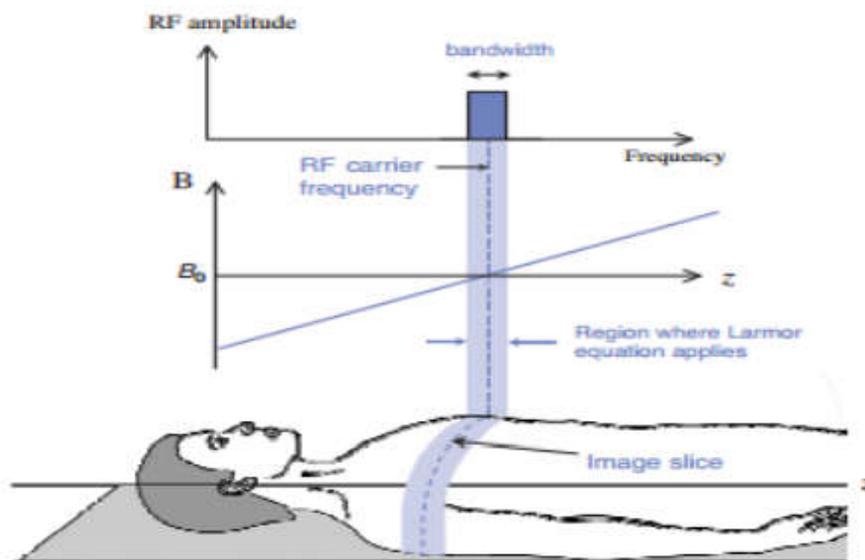


Figure I-14 : Sélection de coupe en IRM [3].

### 5.2. Encodage de phase

L'encodage de phase utilise un gradient de champ magnétique supplémentaire appelé gradient d'encodage de phase  $G_y$ . Ce gradient est utilisé pour différencier les sources de signal le long de la direction  $y$ , l'axe vertical, avant la phase de lecture. Ainsi, la fréquence de rotation des

## Chapitre I:Imagerie par résonance magnétique parallèle

spins est modifiée pour différentes positions le long du gradient. Lorsque le signal est enregistré, ce gradient est désactivé et les spins tournent à nouveau à la même fréquence mais avec une phase différente (voir figure (I-15)) [11].

Le déphasage résultant en fonction de la position le long de l'axe y peut être exprimé à l'aide de l'équation suivante (I.2) :

$$\Delta\Phi (y) = \gamma y G_p t \quad (I.2)$$

$\Delta\Phi (y)$  : Le déphasage, qui représente le changement de phase du signal RMN.

$\gamma$  : La constante de gyromagnétique du noyau atomique.

$\gamma$  : La durée de l'impulsion d'excitation.

$G_p$  : Le gradient de champ magnétique appliqué.

$t$  : Le temps écoulé depuis l'impulsion.

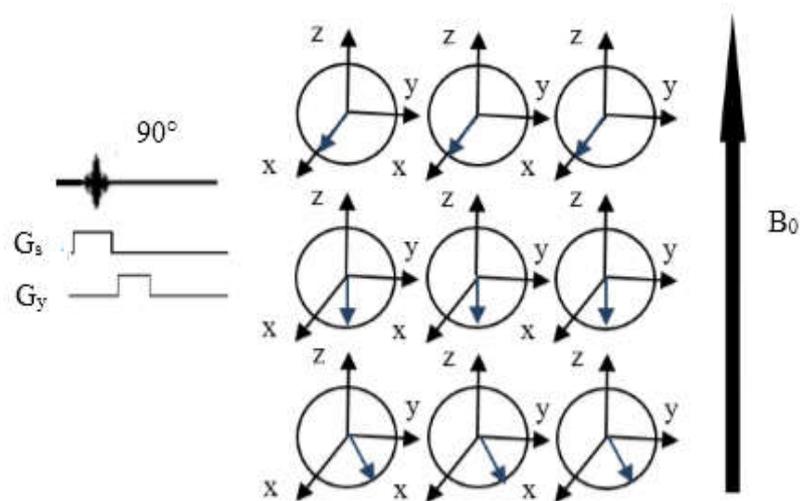


Figure I-15 : Codage de phase.

Ainsi, le codage de phase peut diviser l'objet en plusieurs lignes selon la direction verticale, chaque ligne enregistre un signal RMN de phase différente.

### 5.3. Codage de fréquence

Le diagramme temporel d'une séquence d'imagerie en IRM comprend des entrées et une sortie (voir Figure I-16a). Les entrées RF sont l'impulsion RF associées aux gradients de champ magnétique, tandis que la sortie représente le signal RMN enregistrés au fil du temps. Pour sélectionner une coupe à imager à travers le patient, la séquence nécessite l'activation d'un gradient de champ  $G_z$  en même temps que l'impulsion RF. Une fois que la coupe se sélectionne, le  $G_y$  est activé le long de l'axe y, le gradient d'encodage de fréquence s'active le long de l'axe des abscisses lorsque le  $G_y$  se désactive. Le signal RMN est enregistré au moment où le gradient  $G_x$  est appliqué (voir figure (I-16b)).

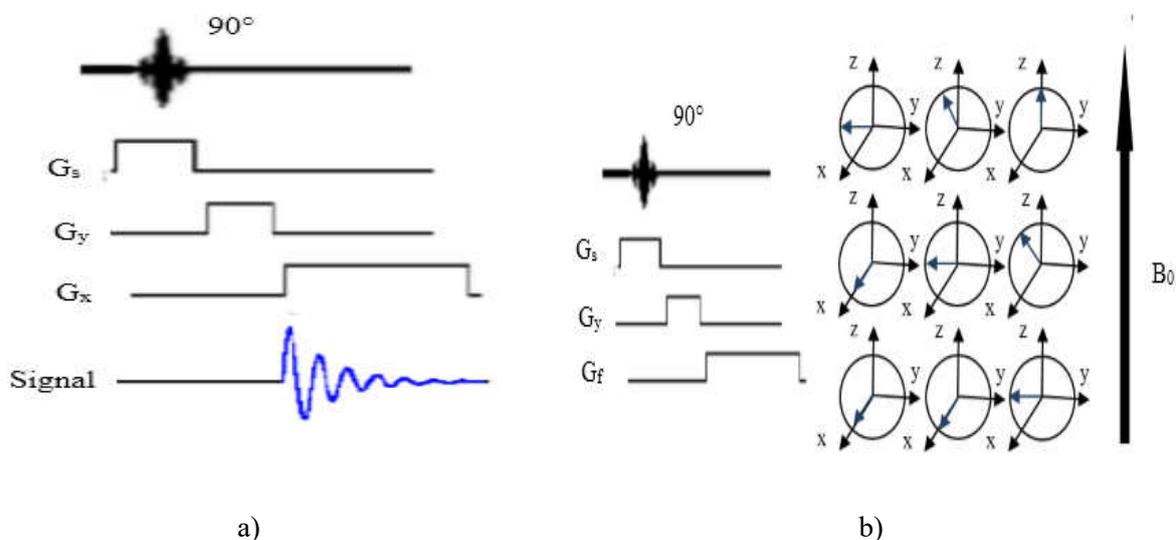


Figure I-16 : a) Diagramme temporel b) Codage de fréquence [4].

## 6. Espace k et formation d'image

Pour décomposer une image en deux dimensions, on applique une transformée de Fourier bidimensionnelle selon les étapes suivantes :

- ✓ La première étape de la transformée de Fourier bidimensionnelle implique l'application d'une transformée de Fourier unidimensionnelle dans la première direction.
- ✓ La deuxième étape de la transformée de Fourier 2D consiste à appliquer une autre transformée de Fourier unidimensionnelle selon la deuxième direction au résultat obtenu lors de la première étape.

Le plan de Fourier est le résultat de la transformation de Fourier bidimensionnelle d'une image, qui est représenté graphiquement par la figure (I-17). Les signaux enregistrés lors

d'une séquence IRM 2D sont représentés dans un espace appelé espace k, qui est comme une carte en deux dimensions qui décrit les fréquences présentes dans les données. L'espace k est basé sur les principes mathématiques de la transformée de Fourier. Il est défini par deux directions,  $k_x$  et  $k_y$ , comme montre la même figure.

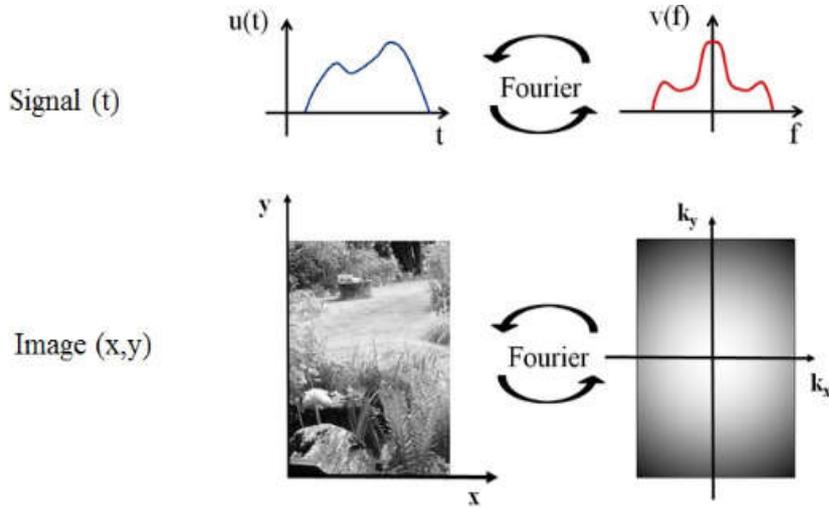


Figure I- 17 : Formation de l'image [4].

L'image d'une coupe à travers le corps humain représente la transformée de Fourier 2D inverse de son espace k. Les coordonnées des points échantillonnés dans cet espace peuvent être exprimées mathématiquement de la manière suivante :

$$k_x(t) = \frac{y}{2\pi} \int_0^t G_x(t') dt' \quad (I.3)$$

$$k_y(t) = \frac{y}{2\pi} \int_0^t G_y(t') dt' \quad (I.4)$$

Au centre de l'espace k, près de l'origine de l'axe, se trouvent les fréquences basses, et les fréquences élevées se situent aux périphéries près des bords de l'espace (figure (I-18)).

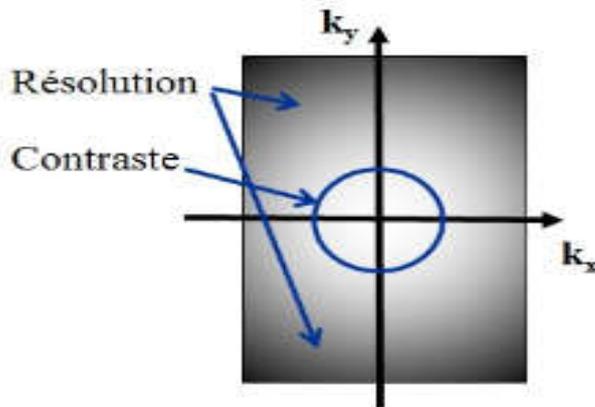


Figure I- 18 : Espace k (contraste et résolution).

## Chapitre I:Imagerie par résonance magnétique parallèle

En IRM, dans une séquence spin-écho, le temps  $\Delta t$  entre deux échantillons définit le FOV ("field of view") de l'image, la largeur de la fenêtre d'échantillonnage définit la largeur des pixels, et donc la limite du taux de résolution.

Le champ de vue (FOV) et la résolution spatiale de l'image sont donnés par :

$$FOV_x = \frac{1}{\delta K_x} \quad (I.5) \quad \text{et} \quad FOV_y = \frac{1}{\delta K_y} \quad (I.6)$$

$$\delta_x = \frac{1}{2K_{xmax}} \quad (I.7) \quad \text{et} \quad \delta_y = \frac{1}{2K_{ymax}} \quad (I.8)$$

Avec :

$\delta_x$  et  $\delta_y$  représentent respectivement la résolution de la fréquence spatiale dans les directions horizontale et verticale  $k_x$  et  $k_y$ .

$K_{xmax}$  et  $K_{ymax}$  sont respectivement les valeurs maximales atteintes dans l'espace-  $k$  selon  $k_x$  et  $k_y$ .

Si on réduit l'espace entre les pixels dans l'une des directions  $x$  ou  $y$  de l'espace  $k$ , le champ de vue (FOV) de l'image augmentera dans cette même direction.

Le temps d'acquisition total (TA) pour collecter un ensemble de données 2D peut être écrit comme :

$$TA = TR \times NPE \quad (I.9)$$

Avec:

TR : le temps de répétition, il correspond au temps requis pour acquérir une ligne de l'espace  $k$  dans la direction  $k_x$ .

NPE : le nombre de lignes de codage de phase dans la direction  $k_y$ .

Pour réduire le temps d'acquisition (TA), on peut diminuer la quantité de données collectées dans l'espace  $k$  (NPE). Cependant, il est important d'utiliser un système puissant qui permet de minimiser le temps d'acquisition tout en préservant les informations précieuses générées par une seule acquisition d'IRM.

### 7. Imagerie parallèle

En IRM classique, les signaux RMN sont obtenus à partir d'une seule antenne de réception, et leur localisation est réalisée en utilisant un codage de gradient. Cependant, la principale limitation pour réduire le temps d'acquisition d'images réside dans le codage de phase, car chaque étape de codage de phase nécessite l'acquisition d'un écho distinct.

Comme indiqué ci-dessus et d'une manière plus approfondie, le temps d'acquisition est déterminé par :

$$T_{image} = T_R N_y N_{ex} \quad (\text{I.10})$$

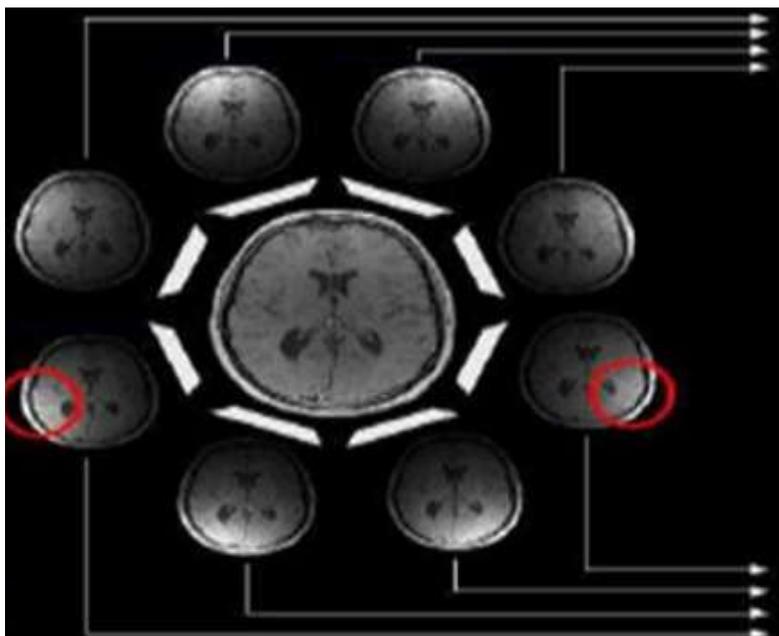
Avec

$T_R$  : le temps de répétition,  $N_y$  : le nombre d'étapes du codage de phase,  $N_{ex}$  : le nombre d'excitation pour moyenner le signal [12].

Pour diminuer le temps d'acquisition des images en IRM, on peut utiliser le principe de l'imagerie parallèle, qui consiste à acquérir l'objet à imager en utilisant plusieurs antennes ( $N_c$ ) en réseau plutôt qu'une seule.

La figure (I-19) explique comment 8 images bobines peuvent être acquises simultanément en utilisant une antenne 8 canaux disposées de manière à couvrir une grande partie de l'objet à imager.

Les zones lumineuses observées sur les 8 images résultent de la sensibilité différente des récepteurs, qui fournissent des informations basées sur leur propre sensibilité spatiale. Cette diversité sera exploitée lors du processus de reconstruction.



**Figure I-19** : Acquisition simultanée de l'objet à imagé à l'aide d'une antenne 8 canaux [3].

### 7. 1. Antennes en réseau phasé

C'est un réseau de bobines de surface de petit diamètre qui sont disposé côte à côte afin d'augmenter le rapport signal sur bruit. Chaque bobine dispose de son propre canal de réception du signal et produit une image de la région anatomique correspondante. Les images bobines sont combinées pour reconstruire l'image finale. Cette approche permet d'obtenir une image finale avec un rapport signal/bruit élevé et offre une couverture étendue de la région à imager.

### 7.2. Méthodes de reconstruction

Les méthodes de reconstruction d'images IRM parallèles ont révolutionné l'imagerie médicale en permettant des acquisitions plus rapides et plus précises des images. Ces techniques sont couramment utilisées dans les cliniques et les centres de recherche, permettant des examens plus rapides pour le patient et des résultats plus précis pour les médecins et les chercheurs.

Les méthodes de reconstruction du signal IRMp peuvent être regroupées en deux principales catégories :

- Reconstruction d'images complexes multiples : Le processus de reconstruction combine les données des différentes bobines pour obtenir une image reconstruite par bobine (reconstruction dans le domaine fréquentiel).

- Reconstruction d'une image complexe unique : Le processus de reconstruction combine les données des différentes bobines avec des informations supplémentaires (telles que la carte de sensibilité de chaque bobine) pour obtenir une seule image dans le domaine spatial, après la transformée de Fourier.

En IRMp, différentes méthodes de reconstruction d'images ont été proposées parmi lesquelles nous pouvons citer les algorithmes basés sur l'espace  $k$ . La méthode d'Acquisition Simultanée des Harmoniques Spatiales (SMASH) est une méthode basée sur l'espace  $k$ , c'est la première technique d'imagerie parallèle expérimentalement réussie, elle utilise des combinaisons linéaires de profils de sensibilité des bobines pour générer des harmoniques spatiales de bas ordre dans le champ de vue souhaité. La méthode d'Acquisitions Partiellement Parallèles Autocalibrantes Généralisées (GRAPPA) est une autre méthode basée sur le principe de SMASH.

D'autres méthodes de reconstruction sont utilisées en IRMp, elles sont basées sur le domaine d'image. Elles comprennent les méthodes : Imagerie partiellement parallèle avec des sensibilités localisées (PILS), codage de la sensibilité (SENSE), imagerie parallèle auto-calibrante avec extraction automatique de la sensibilité de la bobine (SC-SENSE), reconstruction conjointe de l'image et l'estimation de la sensibilité dans SENSE (JSENSE).

Chacune de ces méthodes a ses propres caractéristiques mais le but reste commun, c'est la réduction du temps d'acquisition et l'amélioration de la qualité d'images reconstruites [15] [17].

### 8. Conclusion

A travers ce chapitre, nous avons passé en revue l'appareillage d'IRM et les notions de base de la RMN afin de comprendre le principe de la reconstruction d'image et l'imagerie parallèle. Le chapitre suivant décrit deux méthodes de reconstruction d'images IRMp : GRAPPA et DEEP Learning qui seront l'objet de notre étude.

**Chapitre II: Méthodes de reconstruction d'image  
GRAPPA et DEEP LEARNING**

## 1. Introduction

La reconstruction d'images est un processus crucial en IRM, la qualité des images reconstruite est essentiel pour le diagnostic et le suivi des patients. Ainsi, le temps d'acquisition est un facteur important à prendre en compte lors de la reconstruction d'image. L'acquisition d'images en imagerie parallèle a permis de réduire le temps d'acquisition, mais au détriment de la qualité des images reconstruites, en raison de la présence d'artefact. Plusieurs méthodes de reconstruction d'images ont été développées ces dernières années, dont les techniques d'acquisition partiellement parallèle généralisée (GRAPPA) et de réseaux de neurones convolutifs (CNN) sont parmi les plus couramment utilisées. Dans ce chapitre, nous allons aborder ces deux méthodes de reconstruction qui sont d'une importance majeure pour notre travail. Nous terminons par un état de l'art des travaux de recherche récents.

## 2. Reconstruction par la méthode GRAPPA

La méthode GRAPPA est une méthode de reconstruction d'image IRM parallèle (IRMp) avancée qui permet l'acquisition de données sous-échantillonnées avec plusieurs bobines de réception afin de réduire le temps de balayage IRM et de reconstruire une image sans artefact à partir des données sous-échantillonnées acquises.

L'idée sous-jacente à la méthode de reconstruction GRAPPA est d'estimer les points de données manquants dans l'espace k de chaque bobine réceptrice, à partir du signal d'autocalibrage, connu sous le nom d'ACS [18], qui peut être exprimées mathématiquement comme suit :

$$s_l(\mathbf{k}x, \mathbf{k}y + m\Delta\mathbf{k}x, \mathbf{k}y) = \sum_{j=1}^L \sum_{h=H1}^{H2} \sum_{t=N1}^{N2} \omega_{l,m}(\mathbf{j}, \mathbf{h}, t) s_j(\mathbf{k}x + \mathbf{h} \cdot \Delta\mathbf{k}x, \mathbf{k}y + t \cdot R \cdot \Delta\mathbf{k}y) \quad (\text{II.1})$$

Avec  $S$  : représente le signal de l'espace k.

$W$  : représente les poids d'interpolations.

$k_x, k_y$ : sont les coordonnées de l'espace k le long des directions de codage de phase (PE) et de de fréquence (FE), respectivement.

$\Delta k_x, \Delta k_y$  : sont les intervalles d'échantillonnage le long des directions PE et FE, respectivement.

$j, l$  : représentent les indices des bobines.

$L$  : est le nombre de bobines dans le réseau.

$m$  : est le décalage par rapport aux données acquises.

$N_1, N_2$  : définissent les limites inférieure et supérieure de la fenêtre d'interpolation dans la direction PE.

$H_1, H_2$  : définissent les limites gauche et droite de la fenêtre d'interpolation dans la direction FE, respectivement.

### 2.1 Détermination des poids dans GRAPPA

Généralement, les poids GRAPPA sont dérivés dans l'espace  $k$  en utilisant un ensemble de données d'autocalibrage (ACS) qui est entièrement codé à faible résolution avec un rapport signal sur bruit (SNR) adéquat. Le calcul des poids nécessite les étapes suivantes :

- La première étape consiste à identifier les points source et cible du noyau GRAPPA, en fonction du sous échantillonnage utilisé.
- Dans la deuxième étape, le noyau de reconstruction est appliqué aux données ACS, et les points source et cible pour toutes les répétitions du noyau disponibles, ils sont rassemblés dans des matrices source ( $\mathbf{S}_{src}$ ) et cible ( $\mathbf{S}_{trg}$ ).
- Enfin, les poids de reconstruction ( $w$ ) sont dérivés en résolvant l'équation (II.2) pour l'ensemble de poids de reconstruction souhaité [19].

$$\boldsymbol{\omega} * \mathbf{S}_{src} = \mathbf{S}_{trg} \quad (\text{II.2})$$

La Figure (II-1) illustre un exemple expliquant le calcul des poids à partir d'un espace  $k$  sous-échantillonné d'un facteur d'accélération  $R = 3$ . L'exemple présente un noyau de reconstruction GRAPPA de  $2 \times 3$  dans lequel les points source et cible sont identifiés (dimension omise). Le noyau est glissé dans les données ACS et toutes les répétitions du noyau sont rassemblées dans une matrice source  $\mathbf{S}_{src}$  et une matrice cible  $\mathbf{S}_{trg}$  [19].

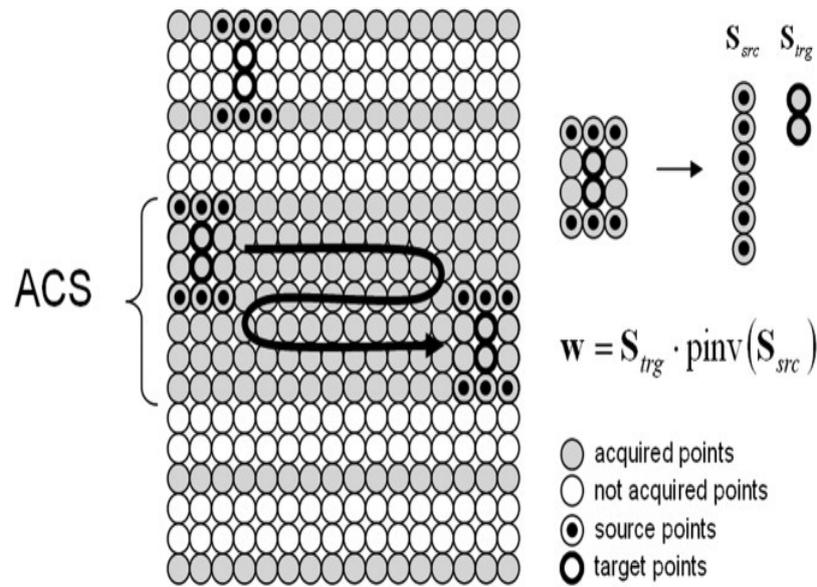


Figure II-1 : Détermination des poids GRAPPA [19].

## 2.2 Processus de la méthode GRAPPA

La reconstruction d'image par la méthode GRAPPA à partir de données partielles acquises grâce à des séquences partiellement parallèles nécessite les étapes suivantes (voir la figure (II-2)):

- **Acquisition de données :** cette étape consiste à numériser les signaux IRM acquis et à remplir la matrice de l'espace k pour chaque bobine. Cependant, en sautant plusieurs étapes d'encodage de phase, de nombreuses lignes de l'espace k sont manquantes. Néanmoins, les lignes centrales de l'espace k sont entièrement échantillonnées et constituent la zone de signal d'autocalibration (ACS) [46].
- **Remplissage des lignes manquantes:** Le nombre de lignes de signal d'autocalibration (ACS) nécessaire dépend généralement du facteur d'accélération, plus le facteur d'accélération est élevé (R), plus il faut de lignes ACS pour maintenir une qualité d'image suffisante. Le signal d'autocalibration est utilisé pour calculer les poids de reconstruction pour chaque bobine, qui sont ensuite utilisés pour remplir les lignes manquantes de l'espace k pour chaque canal [46].
- **Génération d'images individuelles des bobines :** Après avoir rempli les lignes manquantes de l'espace k pour chaque canal, une transformation de Fourier

inverse est réalisée afin de produire des images séparées à partir de chaque bobine.

- **Combinaison** : Les images individuelles des bobines sont enfin combinées à l'aide d'une méthode de somme des carrés pour former l'image finale [46].

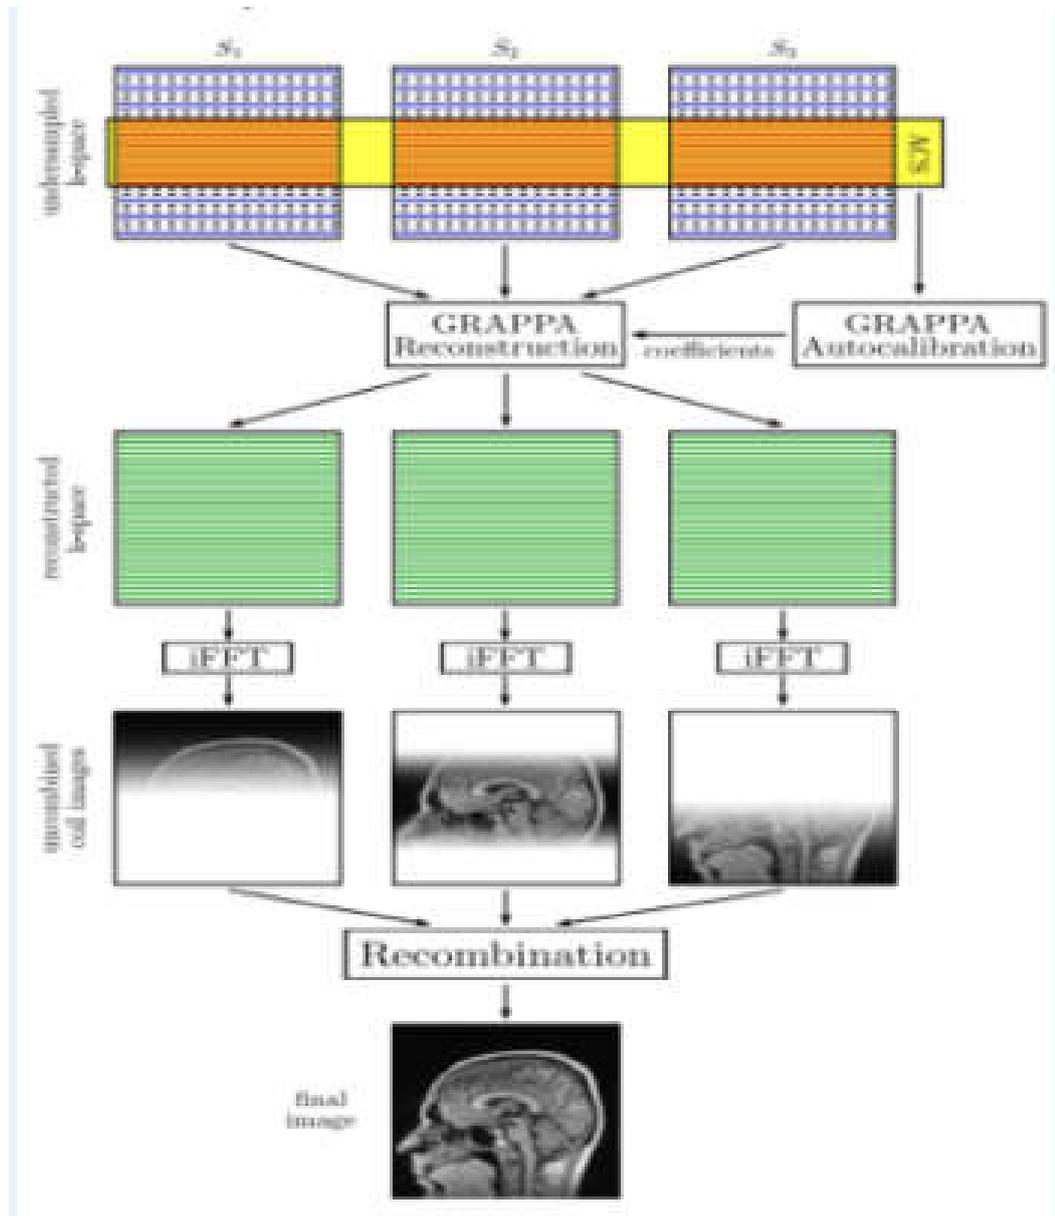


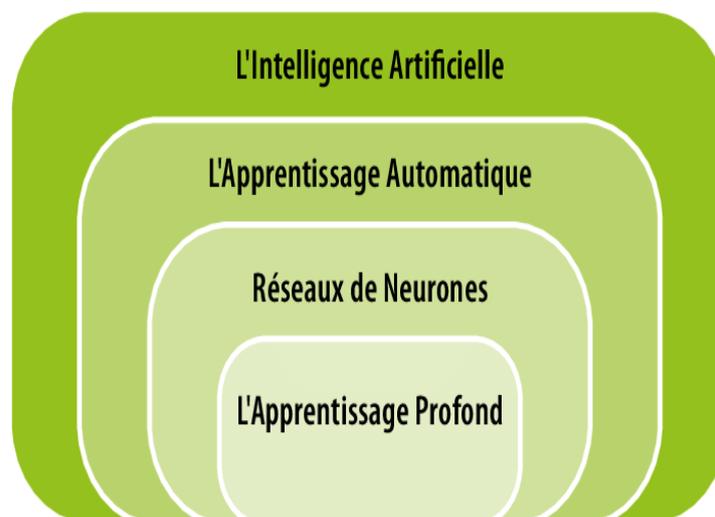
Figure II-2 : Processus de la méthode GRAPPA [4].

### 3. Reconstruction par l'apprentissage profond

Dans cette section, nous allons présenter une méthode de reconstruction plus récente basée sur les techniques d'apprentissages profonds, en particulier les réseaux de neurone convolutif (CNN).

#### 3.1 Apprentissage profond

L'intelligence artificielle (IA) se base sur des concepts tels que les réseaux de neurones, l'apprentissage automatique et l'apprentissage profond. Les réseaux de neurones sont des modèles inspirés du cerveau humain, composés de nœuds interconnectés appelés neurones. L'apprentissage automatique permet aux machines d'apprendre à partir de données sans être explicitement programmées, tandis que l'apprentissage profond utilise des réseaux de neurones profonds pour extraire des caractéristiques complexes des données. Les réseaux de neurones sont la base de l'apprentissage automatique, et l'apprentissage profond est une extension puissante de cette technique, la figure (II-3) représente les sous branches de l'IA et la relation entre eux.



**Figure II-3 :** Sous branches de l'intelligence artificielle.

L'apprentissage profond est l'une des branches de l'apprentissage automatique qui utilise des réseaux de neurones artificiels pour apprendre à partir de données. Dans ce contexte, le terme "profond" fait référence au nombre de couches nécessaires pour traiter et transformer les données.

L'apprentissage profond a récemment montré son potentiel dans de nombreux domaines, dépassant souvent les méthodes traditionnelles. Il utilise l'algorithme de rétropropagation pour

ajuster les paramètres internes du réseau, permettant ainsi de calculer progressivement les représentations de chaque couche à partir des représentations de la couche précédente [20][21].

Les techniques d'apprentissage en profondeur, en particulier les réseaux neuronaux convolutifs (CNN) ont été utilisées dans les modalités d'imagerie médicale, y compris l'IRM.

### 3.2 Réseaux neuronaux convolutifs (CNN)

Les réseaux neuronaux convolutifs constituent un outil puissant et flexible pour les applications de vision par ordinateur et de traitement d'images. Ils présentent des structures de réseaux neuronaux profonds qui prennent un tenseur en entrée et apprennent à partir de celui-ci les modèles, les caractéristiques ou les filtres, en incorporant un extracteur de caractéristiques dans le processus d'apprentissage, plutôt que de se baser sur des extracteurs élaborés manuellement par des experts en la matière [24].

Un réseau de neurones convolutifs peut comporter de nombreuses couches, allant de plusieurs dizaines à plusieurs centaines, et chaque couche apprend à reconnaître différentes caractéristiques présentes dans une image. [22].

#### 3.2.1 Types de couches dans le réseau neuronal convolutif :

Le CNN s'articule autour de l'idée de connectivité locale, où le champ réceptif de chaque neurone est localisé dans une région du neurone présent dans la couche précédente [9]. Son architecture comprend quatre types de couches couramment utilisées : la couche convolutive (CONV), la couche d'activation (ReLU), la couche de mise en commun (POOL) et la couche entièrement connectée (FC).

##### ➤ Couche de convolution (Convolutional layer CONV)

Les réseaux neuronaux convolutifs (CNN) comportent une couche de convolution qui contient des noyaux (ou filtres) avec une certaine largeur, profondeur et hauteur. Cette couche produit des cartes de caractéristiques en calculant le produit scalaire entre les noyaux et des régions locales de l'image. L'opération de convolution permet d'extraire les informations pertinentes de l'image, c'est-à-dire les caractéristiques, en faisant glisser un ensemble de filtres sur l'image. Pendant l'apprentissage, les poids de ces filtres sont mis à jour pour permettre au réseau de reconnaître les images avec précision.

Pour mesurer le volume de la couche de convolution, nous avons besoin de trois hyper paramètres :

- ✓ **Profondeur de la couche** : cela fait référence au nombre de noyaux de convolution (ou le nombre de neurones) associés à un même champ récepteur.
- ✓ **Le pas**: contrôle le déplacement de la fenêtre de convolution à travers l'image d'entrée. Le pas influence la taille de la sortie de la couche de convolution et joue un rôle essentiel dans la réduction de dimension, la préservation des détails et la complexité du modèle. Un pas plus petit permet généralement de conserver plus de détails, mais cela peut également augmenter la complexité du modèle [43].

La figure (II-4) représente un exemple de pas de 2. Lorsque nous utilisons un pas de 2 sur une matrice de  $7 \times 7$ , cela signifie que la fenêtre de convolution se déplacera de deux pixels à la fois lors du balayage de la matrice. Ainsi, à chaque itération, la fenêtre sautera deux pixels horizontalement et verticalement. La taille de la matrice est donc réduite de moitié dans les deux dimensions (horizontale et verticale), elle donne la sortie  $3 \times 3$ .

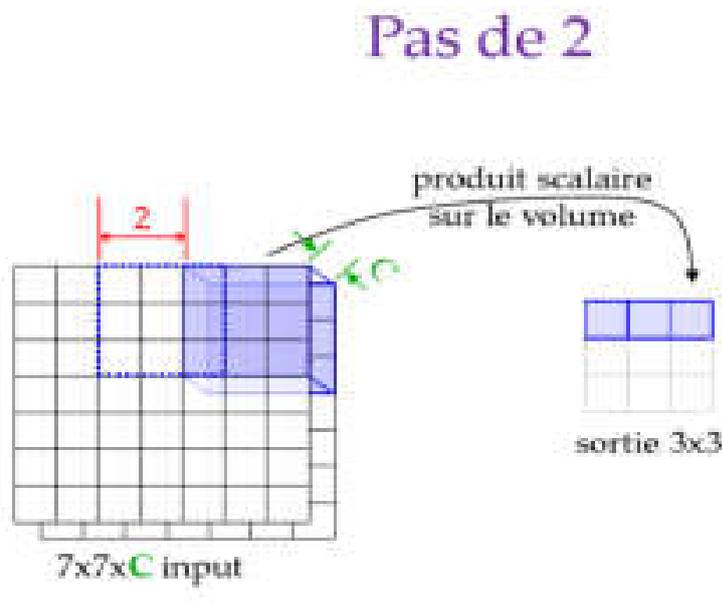
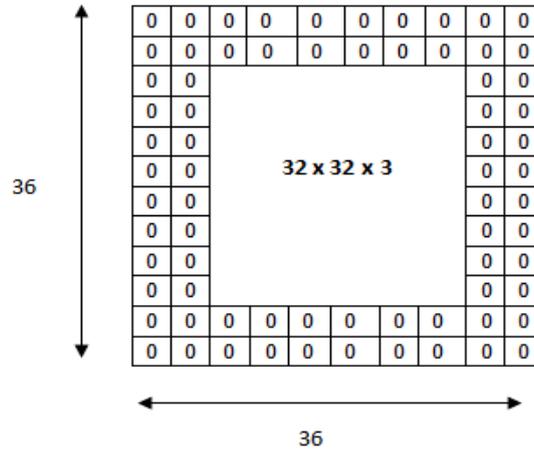


Figure II-4 : Exemple de pas de 2 [43].

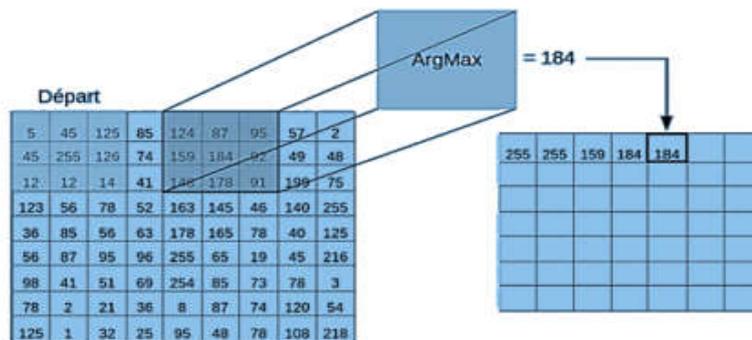
- ✓ **la marge (padding)**: Dans certaines situations, il peut être souhaitable de maintenir les dimensions des images en sortie des convolutions. Le padding consiste à ajouter des zéros autour de la matrice (image) afin d'augmenter sa taille.

Le padding est illustré dans la figure (II-5), où un padding de 2 est appliqué à une matrice de taille 32×32. Cela signifie que des zéros sont ajoutés à gauche et à droite sur 2 colonnes, en haut et en bas sur 2 lignes. Cette opération permet de maintenir la taille de l'image après l'opération de convolution [43].



**Figure II-5 :** Padding de 2 sur une matrice de taille 32×32 [43].

La convolution agit comme un filtre appliqué à une image représentée sous forme de matrice (voir figure II-6). Une fenêtre de taille prédéfinie se déplace à travers l'ensemble de l'image. Au début de la convolution, la fenêtre est positionnée en haut à gauche de l'image. Elle se déplace ensuite d'un certain nombre de pas vers la droite, et lorsque la fin de l'image est atteinte, elle se déplace d'un pas vers le bas. Ce processus se répète jusqu'à ce que le filtre ait parcouru la totalité de l'image [25].



**Figure II-6 :** Processus de convolution [28].

➤ **Couche de correction (Rectified Linear Unit layer ReLU)**

La couche de correction ReLU est une fonction d'activation qui permet de remplacer toutes les valeurs négatives de l'entrée par des zéros, tout en conservant les valeurs positives intactes. la figure (II-7) représente le rôle de la fonction ReLU:

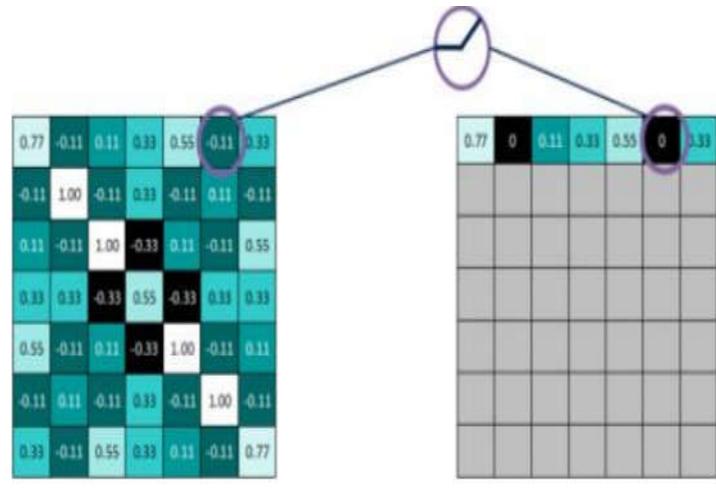


Figure II-7 : Processus de convolution [28].

Il existe plusieurs fonctions d'activations (voir Figure II-8) comme :

- ✓ Fonction à seuil « step »
- ✓ Fonction « sigmoid »
- ✓ La tangente hyperbolique
- ✓ Fonction « ReLU »
- ✓ Fonction « Leaky ReLU »
- ✓ Fonction Unités linéaires exponentielles « Exponential Linear Units ELUs »
- ✓ Fonction « Softmax » .

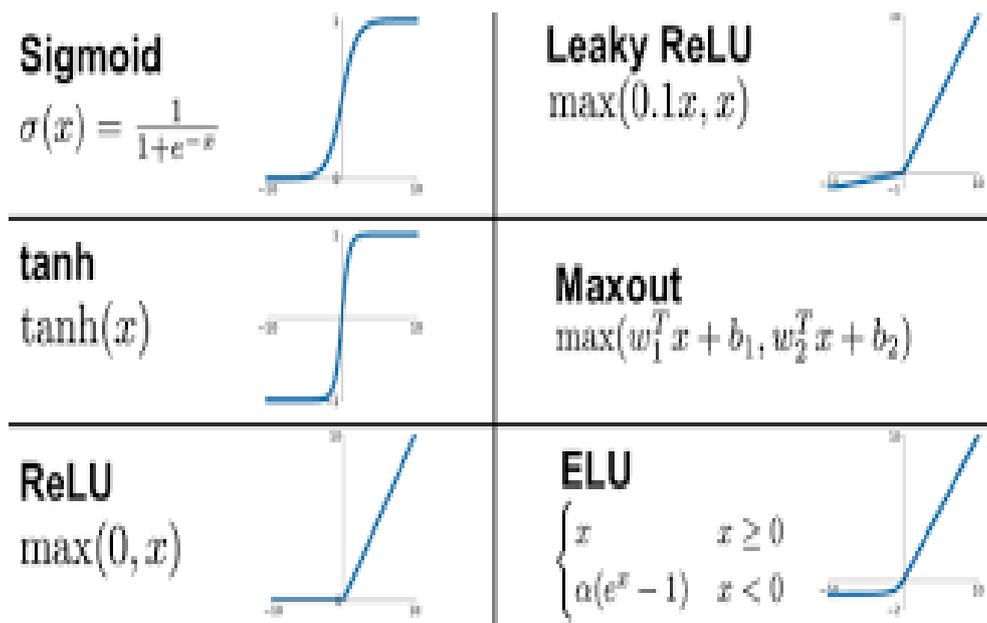


Figure II-9: Fonctions d'activation.

➤ **Couche de pooling (POOL)**

La couche de mise en commun appelée pooling a pour objectif principal de diminuer le nombre de données des cartes d'activation en combinant les informations des pixels voisins. Cela permet de réduire la taille de la carte d'activation tout en préservant les informations importantes pour la couche suivante.

Le regroupement des pixels voisins est généralement effectué en utilisant une matrice carrée et en remplaçant les pixels sélectionnés par la moyenne (average pooling) ou la valeur maximale (max pooling).

Cette couche agit de manière indépendante sur chaque profondeur de l'entrée et réduit la dimension uniquement au niveau de la surface. L'utilisation d'une taille de tuile 2x2 et la sélection de la valeur maximale sont courantes. Cela permet de réduire le nombre de paramètres du modèle [22].

La figure (II-9) représente des exemples d'opération max pooling et average pooling.

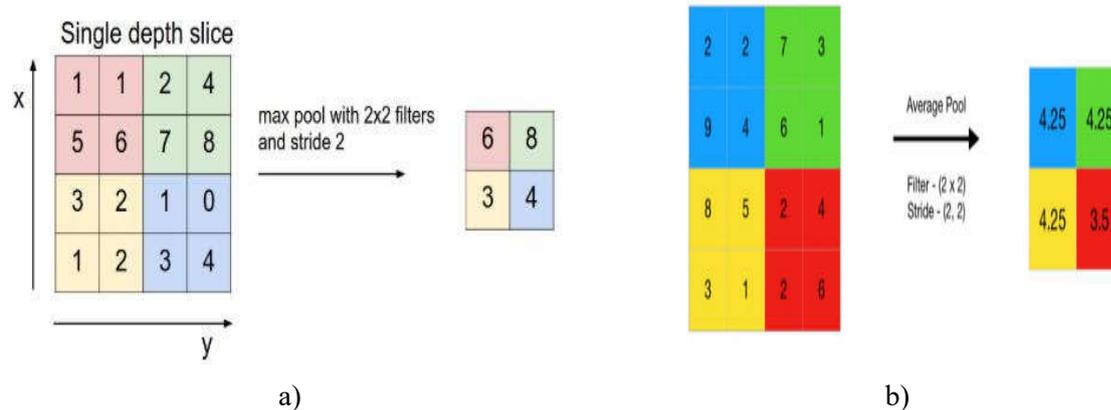


Figure II-9: a) Maxpooling, b) average Pooling [43].

➤ **Couche entièrement connectée (fully connecte layer)**

La dernière couche est généralement constituée d'une couche entièrement connectée. Dans cette couche, chaque neurone établit une connexion avec l'ensemble des neurones de la couche précédente. Elle combine linéairement les entrées reçues, puis applique une fonction d'activation à ces valeurs pour produire une sortie finale [26].

**3.2.2. Architectures de CNN pour la reconstruction :**

Les architectures de CNN (Convolutional Neural Networks) utilisées pour la reconstruction sont des modèles spécifiquement conçus pour la tâche de restauration ou de reconstruction d'images. Ces architectures exploitent les propriétés de convolution et de pooling des CNN pour capturer les caractéristiques importantes de l'image et reconstruire une version améliorée de celle-ci. Différents modèles de reconstruction ont été développés ces dernières années parmi lesquels nous pouvons citer le réseau variationnel, réseau en cascade profonde DCCNN, ConvLSTM et l'autoencodeur.

**3.2.2.1. Réseau variationnel (VR Net)**

Les réseaux variationnel (VR) sont des modèles qui reposent sur les méthodes de gradient proximal incrémentales et qui sont entièrement appris. Ces modèles ont pour but de permettre une reconstruction rapide et de haute qualité des données cliniques d'IRM à bobines multiples. Les paramètres de cette approche, y compris le modèle préalable défini par les noyaux de filtre, les fonctions d'activation et les poids des termes de données, sont tous appris au cours d'une procédure de formation hors ligne. Une fois le modèle appris, il peut être appliqué en ligne à des données inédites. Les reconstructions effectuées par les réseaux variationnels préservent l'aspect naturel des images d'IRM et les pathologies qui n'ont pas été incluses dans

l'ensemble des données d'entraînement. De plus, grâce à leurs performances de calcul élevées et à l'absence de réglage des paramètres une fois le réseau entraîné, les VR sont très pratiques pour une utilisation clinique rapide. Par exemple, un temps de reconstruction de 193 ms sur une seule carte graphique peut être obtenu [27].

### 3.2.2.2. CNN cascadée profonde (DC CNN)

Un nouveau modèle de reconstruction d'IRM a été développé en utilisant un réseau neuronal convolutif (CNN). Ce modèle se compose d'un réseau en cascade appelé DCCNN, dans lequel la couche régulière de cohérence des données (DC) assure la fidélité périodique des données. En outre, cette couche DC calcule la projection de l'estimation de l'image intermédiaire sur le sous-espace non observé du domaine de Fourier, permettant ainsi de sauvegarder et de réutiliser les images intermédiaires d'innovation dans la dernière étape de la structure globale via des connexions de saut. Ce modèle en cascade offre des performances de reconstruction supérieures à celles des approches récentes de réseau profond [28].

### 3.2.2.3. Mémoire convolutive à long terme en cascade (ConvLSTM)

L'objectif de cette architecture est de reconstruire des séquences d'IRM dynamiques pondérées en T2 à partir de données fortement sous-échantillonnées dans l'espace k, afin d'accélérer le processus d'acquisition global. Pour ce faire, les données entièrement échantillonnées acquises à partir de la base de données sont soumises à un masque de sous-échantillonnage cartésien. L'approche ConvLSTM est utilisée pour éliminer les artefacts de repliement introduits par le sous-échantillonnage. De plus, le modèle ConvLSTM apprend les dépendances spatiales et temporelles de l'imagerie pour une reconstruction efficace, surpassant la précision de reconstruction basée sur le réseau neuronal convolutif (CNN) [29].

### 3.2.2.4. Auto encodeur CNN

Les auto encodeurs sont une famille importante de réseaux neuronaux conçus pour reconnaître les modèles inhérents aux données et coder leur propre structure. Le but de l'auto encodeur est de minimiser l'erreur de reconstruction entre l'entrée et la sortie, en préservant les éléments les plus importants de l'image, et en conservant ses caractéristiques essentielles [30].

L'auto encodeur utilise plusieurs paramètres de formation :

- ✓ Taille du code : taille des données compressées (nombre de nœuds dans la couche intermédiaire)

- ✓ Nombre de couches : aussi profond que vous le souhaitez
- ✓ Fonction de perte : erreur quadratique moyenne ou entropie croisée binaire (si les valeurs d'entrée sont comprises dans l'intervalle [0,1])
- ✓ Nombre de nœuds par couche - la structure des couches est généralement symétrique pour le codeur et le décodeur, et le nombre de nœuds diminue le "code" (données compressées) [31].

Le modèle auto encodeur se compose de deux parties : un encodeur qui transforme l'entrée en une représentation plus compacte, et un décodeur qui reconstruit l'entrée à partir de cette représentation.

### Étape encodeur :

La figure (II-10) représente un exemple de l'auto encodeur CNN, la partie codeur comprend trois couches de convolution tridimensionnelles pour l'extraction des caractéristiques et le sous-échantillonnage des données d'entrée. Chaque couche de convolution comprend plusieurs canaux correspondant aux différentes caractéristiques à apprendre [30]. L, W et H sur la figure représentent respectivement la longueur, la largeur et la hauteur de la résolution de l'image d'entrée.

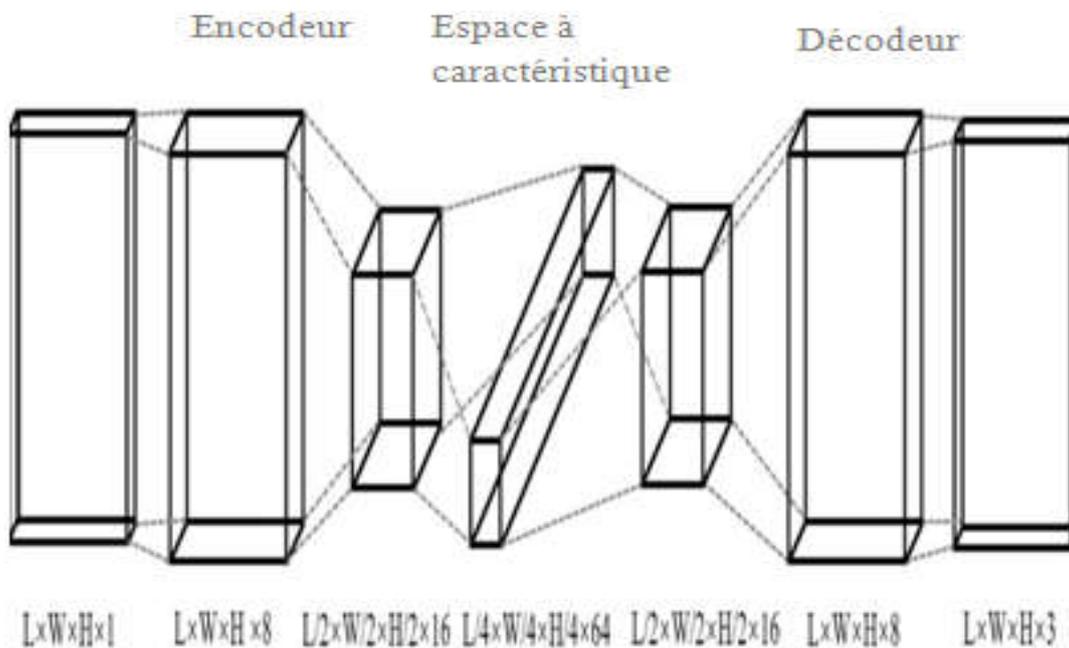


Figure II-10 : Schéma du CNN codeur-décodeur [30].

- L'encodeur prend l'image  $x$  en entrée, et la transforme en une représentation compressée dans un espace latent. Cette transformation se fait en plusieurs étapes :
  - ✓ **Convolution** : application de filtres pour extraire des caractéristiques de l'image.
  - ✓ **Fonction d'activation** : introduction de la non-linéarité dans le modèle.
  - ✓ **Pooling** : réduction de la résolution spatiale de l'image tout en préservant les caractéristiques importantes  
Répétition des étapes de convolution, d'activation et de pooling pour extraire des caractéristiques de plus en plus abstraites de l'image.
  - ✓ **Réduction de la dimensionnalité** : compression de l'image dans un espace latent tout en préservant les caractéristiques importantes.

Les données encodées, sont calculées comme suit [30]:

$$E=f(W*x+\alpha) \quad (\text{II.3})$$

Avec :

**W** et  **$\alpha$**  : sont respectivement les filtres et le biais de la carte des caractéristiques encodées.

**$f(.)$**  : est une fonction d'activation.

- **Étape du décodeur** : Le décodeur prend cette représentation compressée et la décode en une sortie qui est une reconstruction de l'entrée originale. Cette transformation se fait en plusieurs étapes :
  - ✓ **Déconvolution** : inversion du processus de convolution pour reconstruire l'image à partir de la représentation latente.
  - ✓ **Fonction d'activation** : introduction de la non-linéarité dans le modèle.
  - ✓ **Dé-pooling** : Augmentation de la précision spatiale de l'image reconstruite.
  - ✓ **Décompression** : augmentation de la dimensionnalité de l'image reconstruite pour produire une sortie de la même taille que l'entrée d'origine.
  - ✓ Les étapes de déconvolution, d'activation et de dé-pooling se répètent à chaque itération pour reconstruire l'image à partir de la représentation latente

Les données décodées  $D$ , sont calculées comme suit (équation (II.4)):

$$D=f(E*W^T + \alpha^T) \quad (\text{II.4})$$

Avec :

$E$  : représente l'état caché (les données encodées).

$W^T, \alpha^T$  : sont respectivement les filtres et le biais de la carte des caractéristiques décodées.

$f(.)$  : est une fonction d'activation.

Dans notre projet fin d'étude, nous avons choisi ce dernier modèle afin d'effectuer une tâche de compression de données, en entraînant le modèle sur un ensemble de données et en testant sa capacité à reconstruire des images avec une qualité acceptable.

### 4. Etat de l'art

La méthode GRAPPA est une technique de reconstruction d'image IRM plus performante, couramment utilisée dans les applications cliniques. La reconstruction d'images est un domaine de recherche en évolution, avec une attention croissante accordée aux méthodes d'apprentissage profond. C'est pourquoi, il est important de consulter l'état de l'art actuel.

La section suivante décrit quelques travaux de recherches les plus récents :

- Mehmet Akçakaya, et al, « **Scan-specific robust artificial-neural-networks for k-space interpolation (RAKI) reconstruction: Database-free deep learning for fast imaging** », 2018.

Dans cet article, Les auteurs ont présenté une méthode novatrice de reconstruction d'images à partir de données incomplètes appelée RAKI (Robust Artificial-Neural-Networks for k-space Interpolation). Ils ont présenté son architecture basée sur le réseau de neurones artificiels permettant une reconstruction rapide à partir de données sous-échantillonnées.

Leurs résultats ont démontré que la méthode RAKI permet d'obtenir des images de qualité comparable ou supérieure à celles obtenues avec des méthodes de reconstruction conventionnelles avec un temps de calcul réduit [40].

- Ruizhi Hou, Fang Li, « **IDPCNN: Iterative denoising and projecting CNN for MRI reconstruction** », 2021.

Dans cet article, les auteurs ont utilisé des données incomplètes et bruitées. Ils ont proposé une méthode de reconstruction basée sur les réseaux de neurones convolutifs itératif. A chaque itération, le réseau de neurones combine l'étape de projection des données d'IRM

incomplètes et l'étape de débruitage, l'image reconstruite est utilisée comme point de départ de la prochaine itération.

Les résultats ont montré que la méthode proposée permet d'obtenir une meilleure qualité d'image que les méthodes classiques avec une complexité de calcul raisonnable [38].

- Jinhong Huang, et al, « **Evaluation on the generalization of a learned convolutional neural network for MRI reconstruction** »,2022

Cet article a décrit la méthode du réseau neuronal convolutif (CNN) généralisé évalué pour la reconstruction d'images IRM.

Les performances du CNN sont évaluées sur un ensemble de données IRM distinct, différentes mesures de performance sont utilisées, notamment le PSNR (Peak Signal-to-Noise Ratio) et le SSIM (Structural Similarity Index Measure) ; des techniques de visualisation sont aussi utilisées pour analyser les résultats du CNN et identifier les caractéristiques qui sont apprises par le réseau.

Les auteurs ont utilisé la technique de carte, ce sont des représentations visuelles qui mettent en évidence les zones d'intérêt ou les zones d'activité importante dans une image ou une carte, elles peuvent être utilisées pour visualiser les zones de l'image d'entrée qui sont les plus importantes pour la prédiction de l'image de sortie.

Les résultats ont montré que cette méthode peut être utilisée pour évaluer la qualité de la reconstruction IRM et identifier les caractéristiques importantes apprises par le réseau [39].

- Omair Inam, et al, « **GPU accelerated Cartesian GRAPPA reconstruction using CUDA** »,2022.

Dans cet article, les auteurs ont amélioré la méthode GRAPPA en utilisant des GPU. Ils ont implémenté GRAPPA en utilisant le langage de programmation CUDA (Compute Unified Device Architecture) de NVIDIA qui permet l'exécution sur des GPU. La méthode proposée utilise un sous-échantillonnage cartésien permettant d'accélérer les données IRM, puis l'algorithme GRAPPA pour reconstruire l'image finale.

Les résultats expérimentaux ont démontré que la méthode proposée est plus rapide et que les images reconstruites présentent une qualité comparable à celles obtenues avec les méthodes utilisant le processeur central (CPU). [18].

- Worapan Kusakunniran, et al, « **Fast MRI reconstruction using StrainNet with dual-domain loss on spatial and frequency spaces** » ;2023.

Les auteurs de cet article ont proposé une méthode de reconstruction IRM plus rapide en utilisant une approche d'apprentissage profond, connue sous le nom de "StrainNet". Cette méthode utilise une architecture de réseau neuronal convolutionnel permettant de reconstruire des images de haute qualité à partir de données sous-échantillonnées de l'espace k. L'architecture StrainNet se compose d'un ensemble de modules d'encodage et de décodage, qui sont utilisés pour apprendre la correspondance entre les données de l'espace k sous-échantillonnées et les images de haute qualité correspondantes. La partie encodeur se compose de plusieurs couches convolutives qui extraient les caractéristiques des données de l'espace k d'entrée, et la partie décodeur elle aussi se compose de plusieurs couches convolutives et de couches de sur échantillonnage, qui reconvertissent les caractéristiques codées dans le domaine de l'image.

Les résultats ont montré que la méthode StrainNet était plus performante en termes de qualité et de vitesse de reconstruction. La méthode a atteint une vitesse de reconstruction 12 fois plus rapide que les méthodes traditionnelles [33].

- Abdul Basit, et al, « **Accelerating GRAPPA reconstruction using SoC design for real-time cardiac MRI** », 2023.

Dans cet article, les auteurs ont utilisé des données IRM cardiaques et ont proposé une méthode de reconstruction GRAPPA accélérée en utilisant un système-sur-puce (SoC) spécialement conçu. Cette méthode intègre l'algorithme GRAPPA dans une plate-forme matérielle composée d'un dispositif de grille programmable (FPGA) et d'un processeur de signal numérique (DSP). Ces deux composants travaillent en tandem pour accélérer le calcul de l'algorithme GRAPPA. Le FPGA est utilisé pour paralléliser les calculs, tandis que le DSP prend en charge les tâches du traitement du signal.

Les résultats obtenus ont démontré que cette méthode était capable d'accélérer la reconstruction d'images par un facteur de 8 par rapport à la méthode GRAPPA conventionnelle. De plus, le temps de reconstruction était inférieur à 20 millisecondes par image, ce qui permet d'envisager des applications en temps réel telles que l'IRM cardiaque. Ces résultats indiquent l'efficacité de l'approche SoC dans l'accélération des calculs de

reconstruction d'IRM, offrant ainsi des possibilités d'amélioration significative de la vitesse de traitement dans le domaine médical [34].

- Guan Qiu Hong, et al, « **Dual-domain accelerated MRI reconstruction using transformers with learning-based undersampling** », 2023.

Cette méthode utilise des réseaux de neurones de type Transformer basés sur l'apprentissage des données sous-échantillonnées. Les données d'entrée sont transformées en deux domaines, à savoir le domaine spatial et le domaine de Fourier. Les réseaux de neurones de type Transformer sont appliqués par la suite pour l'apprentissage des données et l'image complète se reconstruit à partir des deux domaines de données sous-échantillonnées.

Les auteurs ont montré que cette méthode permet une reconstruction d'image à partir d'un sous-échantillonnage de seulement 10% des données d'entrée. Les résultats ont confirmé une précision avec une rapidité d'acquisition, ce qui représente une amélioration significative par rapport aux méthodes de reconstruction traditionnelles [35].

- Zongjiang Tu, et al, « **K-space and image domain collaborative energy-based model for parallel MRI reconstruction** », 2023.

Les auteurs ont proposé un modèle collaboratif d'énergie qui intègre à la fois une fonction d'énergie dans le domaine de l'espace k et une fonction d'énergie dans le domaine d'image. Ces deux fonctions sont reliées par une contrainte de compatibilité. La résolution du modèle se fait à l'aide d'une méthode itérative qui utilise une descente de gradient alternée pour minimiser la fonction d'énergie globale.

Les résultats indiquent que cette méthode puisse être mise à profit pour améliorer la qualité des images IRM parallèles dans des contextes cliniques [36].

- Jijie Hane, et al, « **Improved Parallel Magnetic Resonance Imaging Reconstruction with Sampling based on Normal Distribution** », 2023.

Dans cet article, les auteurs ont proposé une nouvelle technique de reconstruction GRAPPA qui permet de réduire significativement le nombre de lignes ACS tout en améliorant la qualité de l'image. En basant sur l'idée que les données au centre de l'espace k ont un impact plus important sur la qualité de l'image, cette technique permet de prendre en compte les données de manière non linéaire et de réduire le nombre de données acquises à partir des bords de l'espace k.

Les résultats expérimentaux ont montré que la méthode proposée permet de réduire le nombre de lignes d'auto-calibration nécessaires tout en améliorant significativement la qualité de l'image obtenue [37].

### 5. Conclusion

La reconstruction d'images IRMp sous-échantillonnées est un domaine de recherche actif dans lequel de nombreuses techniques ont été proposées. Deux approches populaires sont présentées à travers ce chapitre, à savoir la méthode GRAPPA et la méthode CNN. La reconstruction GRAPPA est une méthode classique basée sur les données échantillonnées auto-calibrées (ACS) qui permettent de reconstruire des images IRM de haute qualité. La méthode CNN est une autre méthode performante qui utilise un réseau de neurones artificiels profond pour apprendre la relation entre les données d'entrée sous-échantillonnées et les images reconstruites. Le prochain chapitre est conservé pour nos applications qui demandent d'étudier ces deux méthodes.

## **Chapitre III : Simulation numérique des méthodes de reconstruction d'image**

### 1. Introduction

En imagerie parallèle, plusieurs méthodes de reconstruction d'image existent ; parmi ces méthodes, nous pouvons citer la reconstruction GRAPPA qui est une méthode récente, performante et très utilisée dans les applications médicales. Plusieurs travaux et différents chercheurs ([18], [34]) ont montré ses avantages par rapport aux autres méthodes. Cependant, le temps d'acquisition des images IRM reste lent malgré tous ses bénéfices.

L'apprentissage profond est un autre domaine qui est devenu un outil très puissant dans ces dernières années. Plus particulièrement, les réseaux de neurones convolutionnels (CNN) qui sont couramment utilisés dans la classification d'images, mais leur utilité ne se limite pas à cette tâche. En effet, ils sont également utilisés pour la reconstruction d'images.

Pour toutes ces raisons, nous avons proposé dans ce projet fin d'étude d'améliorer la reconstruction GRAPPA en utilisant l'apprentissage profond. Dans ce chapitre, nous allons commencer par présenter les différentes données utilisées pour tester nos applications suivies par l'environnement de travail et matériel utilisés. Nous allons présenter par la suite les différents paramètres de performance que nous avons utilisés pour étudier la qualité des images reconstruite par les différentes applications. Ensuite, nous allons étudier les deux méthodes de reconstruction d'images : GRAPPA et CNN afin d'examiner les performances de notre approche. Enfin, nous allons présenter notre interface graphique dédiée à la reconstruction d'image IRM.

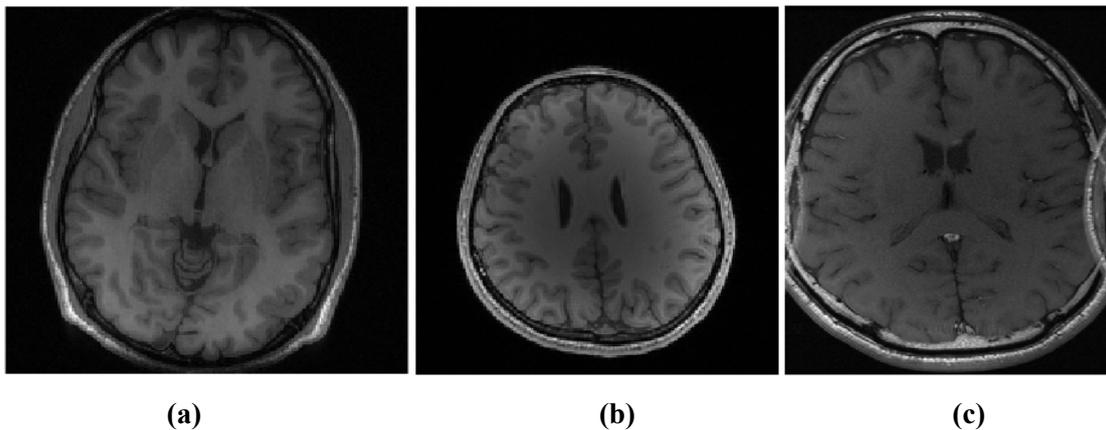
### 2. Données utilisées

Dans notre travail, différents tests ont été appliqués sur des données fantôme et réelles du cerveau. Les données réelles sont acquises d'un appareil IRM 1,5 Tesla (GE, Waukesha, WI). Trois types de données réelles sont utilisés. Deux types de données sont obtenues à partir des bobines 8 canaux et l'autre à partir de bobine 32 canaux.

La **figure III-1a** représente une coupe d'image correspondante aux données obtenues à travers un volume 3D de séquence spoiled écho de gradient (SPGR) de paramètres : TE = 8 ms, TR = 17,6 ms, angle de bascule (FA) = 20°, champ de vue (FOV) = 20 cm × 20 cm × 20 cm et matrice de taille = 200 × 200 × 200 et résolution : 1 mm isotrope.

La **figure III-1b** représente une autre coupe d'image correspondante aux données multicoupes d'espace k pondérées en T2 obtenues à partir d'un cerveau d'un volontaire sain en utilisant une séquence FSE de paramètres : matrice de taille:  $193 \times 192 \times 32$ , résolution=0,82 mm, épaisseur de coupe=3 mm, train d'écho=15 et TR/TE=4,200/85 ms

La **figure III.1c** représente la troisième coupe d'image correspondante aux données acquises d'une séquence d'écho de gradient préparé par inversion-récupération de paramètres :TR/TE=9.7/4.1 ms TI=450 ms, FA=20°, bande passante=15 kHz, taille de matrice=  $320 \times 256 \times 8$ , et résolution : 1 mm isotrope.[47].



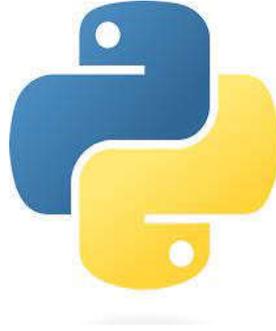
**Figure III-1** :Images correspondent aux données réelles (a) image brain\_8ch (b) image brain\_32ch, (c) brain\_alias\_8ch[47].

### 3. Environnement de travail

Dans nos applications, nous avons choisi deux types d'environnement de travail à savoir Python et Matlab.

#### 3.1 Python

Python est le langage de programmation open source le plus largement utilisé par les informaticiens. Il occupe une place prépondérante dans la gestion de l'infrastructure, l'analyse de données et le développement de logiciels. Il est particulièrement populaire dans les domaines de la science des données, de l'apprentissage automatique, de l'intelligence artificielle et du calcul scientifique. Python offre une vaste gamme de bibliothèques dédiées à la science des données et au calcul scientifique, telles que NumPy, Pandas, Scikit-Learn et TensorFlow[44]. Son logo est représenté par la Figure III-2.



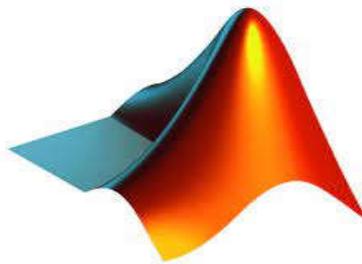
**Figure III-2:** Logo Python.

### 3.2 MATLAB

MATLAB est une plateforme de programmation spécialement conçue pour les ingénieurs et les scientifiques, qui leur permettent d'analyser et de concevoir des systèmes et des produits ayant un impact sur notre monde. Le langage principal de MATLAB est un langage basé sur les matrices, offrant une expression naturelle des calculs mathématiques [45].

En plus d'être un langage de programmation, MATLAB est également un environnement de développement intégré (IDE) qui propose de nombreux outils et modules complémentaires pour des domaines spécifiques tels que la modélisation de systèmes dynamiques, l'optimisation et la simulation de circuits électroniques.

Nous avons spécialisé ce langage pour développer une interface graphique permettant la reconstruction des images IRM à partir des données réelles en utilisant les méthodes les plus sophistiquées telles que GRAPPA et Deep Learning .



**Figure III-3:** Logo MATLAB.

### 3.3 Matériel utilisé

La configuration du matériel utilisé dans notre implémentation est la suivante:

- Micro portable de type DELL I5, CPU 2.30 GHZ

- Système d'exploitation 64 bits Windows 10 Professionnel
- Une mémoire vive RAM de taille 8 GO

### 4. Paramètres d'évaluations

Les paramètres d'évaluation sont des mesures quantitatives utilisées pour évaluer la qualité des images obtenus. Trois paramètres sont utilisés dans ce travail : PSNR (le rapport signal sur bruit), RLNE (Erreur relative de la norme L 2) et MSSIM (Indice de similarité structurelle moyen).

#### 4.1 Rapport signal sur bruit (PSNR) :

Le PSNR mesure la fidélité de l'image en termes de rapport signal sur bruit, il est exprimé en décibels (dB). Plus le PSNR est élevé, plus la qualité de l'image reconstruite est meilleure.

Le PSNR se calcul comme suit :

$$\text{PSNR} = 10 \log \left( \frac{256}{\sqrt{\text{MSE}}} \right) \quad (\text{III.1})$$

Où MSE est la moyenne de l'erreur quadratique, elle est définie comme suit :

$$\text{MSE} = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [a_{ij} - b_{ij}]^2 \quad (\text{III.2})$$

Avec, a : image référence et b : image reconstruite de taille  $m \times n$ .

#### 4.2 Erreur relative de la norme L 2 (RLNE) :

Le RLNE mesure l'erreur relative de la norme L2 de l'image, c'est un indicateur de fidélité de l'image reconstruite. Plus le RLNE est faible, plus la qualité de l'image reconstruite est meilleure.

Le RLNE est défini par :

$$\text{RLNE}(b) = \frac{b-a}{a} \quad (\text{III.3})$$

Avec b : image reconstruite, et a : image initiale.

#### 4.3 Indice de similarité structurelle moyen (MSSIM) :

Le MSSIM mesure la similarité structurelle entre l'image de référence et l'image reconstruite. Il est basé sur la comparaison de la luminance, du contraste et de la structure de l'image. Plus le MSSIM s'approche de 1, plus la qualité de l'image reconstruite est meilleure.

Le MSSIM est définie  $MSSIM(a, b) = \frac{1}{N} \sum_{j=1}^M (SSIM(a, b))$  (III.5)

Avec : a, b sont l'image de référence et l'image reconstruite, respectivement; et M est le nombre de fenêtres locales de l'image.

La forme générale de l'indice de similarité structurelle (SSIM) est définie par :

$$SSIM(a, b) = [I(a, b)]^\alpha \times [c(a, b)]^\beta \times [s(a, b)]^\gamma \text{ (III.6)}$$

Où : x et y représentent les deux images à comparer,

$l(x, y)$  mesure la similarité de luminance,

$c(x, y)$  mesure la similarité de contraste et  $s(x, y)$  mesure la similarité de structure.

Les valeurs  $\alpha$ ,  $\beta$  et  $\gamma$  sont des paramètres qui peuvent être ajustés.

Différents algorithmes ont été étudiés en se basant sur les paramètres d'évaluations.

### 5. Etude d'algorithmes de reconstruction

Nous avons concentré notre travail sur les deux algorithmes de reconstruction : GRAPPA et CNN afin de nous familiariser vers une autre approche de reconstruction GRAPPA améliorée.

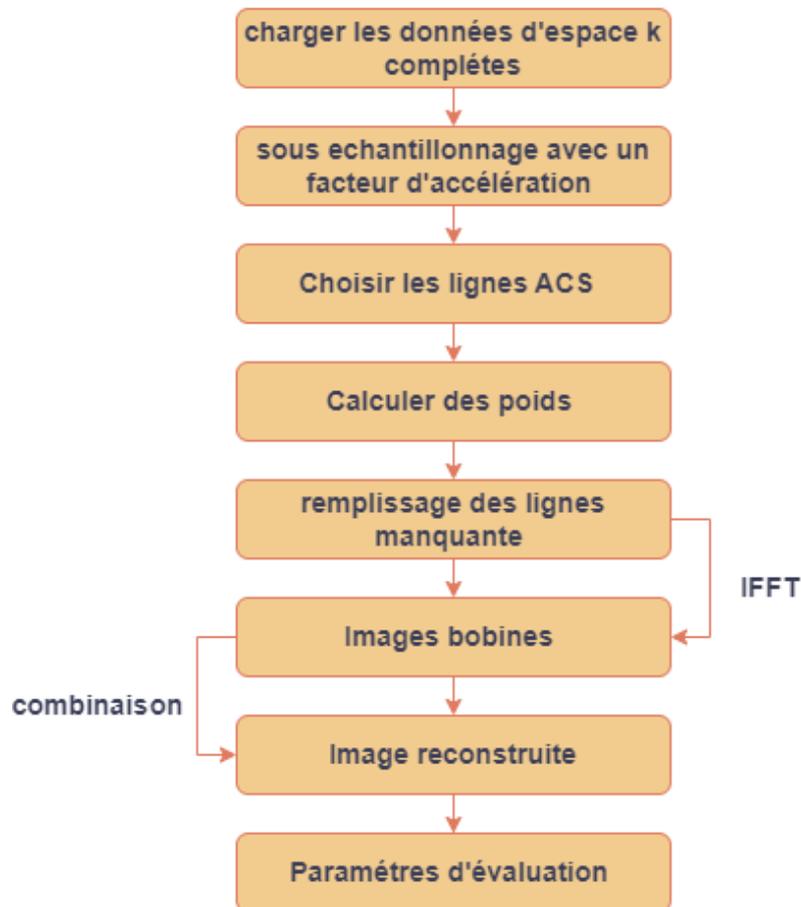
Afin d'étudier les performances des différents algorithmes utilisées, nous les avons testés sur des données fantôme ; ensuite, nous les avons appliqués sur des données réelles du cerveau.

#### 5.1 Algorithme de Grappa

Nous avons appliqué la reconstruction GRAPPA (vue en détail dans le chapitre 2) sur différents types de données 'fantôme et réelles' en passant par les étapes suivantes :

- Charger les données d'espace k.
- Entrer le facteur d'accélération, le nombre de lignes ACS, le nombre de bobines.
- Sous-échantillonner les données d'espace k le long de la direction de lignes en fonction du facteur d'accélération saisi.
- Remplissage de lignes manquantes après le calcul des poids.
- Reconstruire les données d'espace k complet en effectuant une transformée de Fourier inverse sur l'ensemble des données d'espace k à l'aide de la fonction `ifft2`.
- Reconstruire l'image finale à partir de la somme des carrés des images bobines,
- Évaluer la qualité d'image reconstruite en utilisant les paramètres d'évaluation.

Le diagramme de la **Figure III-2** explique les différentes étapes suivies :



**Figure III-4:** Organigramme de la méthode de reconstruction GRAPPA.

Pour toutes les applications, nous avons choisi un facteur d'accélération  $R=2$ , un nombre de lignes ACS de 32 et différents nombres de bobines '8 et 32'.

### 5.1.1 Reconstruction GRAPPA sur les données fantôme :

L'image fantôme de type Shepp-Logan est une référence couramment utilisée dans le domaine de la reconstruction d'images médicales. Elle est spécialement conçue pour évaluer les performances des algorithmes de reconstruction d'images.

La **Figure III-5b** représente l'image fantôme reconstruite par l'algorithme GRAPPA à partir des données fantôme représentées sous forme d'image par la **Figure III-5a**.

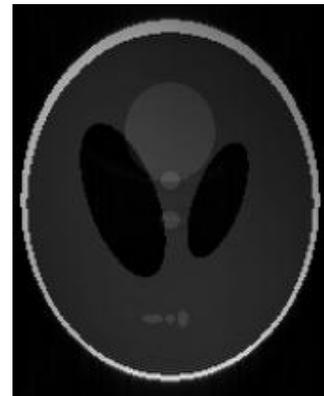
Pour évaluer les performances de l'algorithme, nous avons calculé les paramètres d'évaluation et mesuré le temps d'acquisition. Le tableau (III-1) représente les paramètres d'évaluation obtenus à partir de l'image reconstruite.

**Tableau III-1** : Paramètres d'évaluations obtenus à partir de l'image fantôme reconstruite par la méthode GRAPPA

Paramètres	Valeurs
PSNR	64.0975
RLNE	0.0727
MSSIM	0.9994
Temps	5.413 s



(a)



(b)

**Figure III-5:** Image originale de fantôme (a) et image reconstruite par la méthode GRAPPA (b).

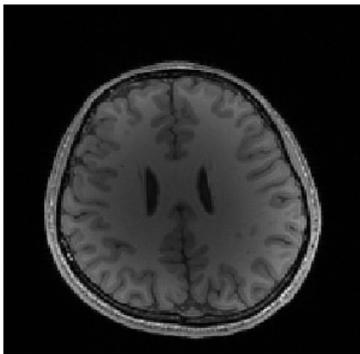
### 5.1.2 Reconstruction GRAPPA sur les données réelles :

La figure (III-6b) représente l'image reconstruite par la méthode GRAPPA à partir des données réelles représentées sous forme d'image par la Figure III-6a.

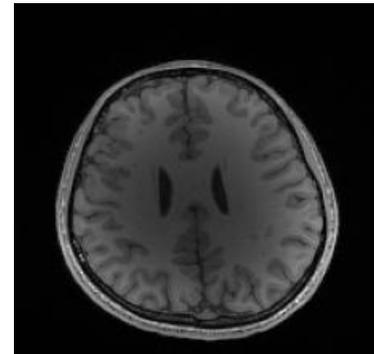
Pour évaluer les performances de l'algorithme, nous avons calculé les paramètres d'évaluation et mesuré le temps d'acquisition. Le tableau (III-2) représente les paramètres d'évaluation obtenus à partir de l'image reconstruite.

**Tableau III-2 :** Paramètres d'évaluations obtenus à partir de l'image réelle reconstruite par la méthode GRAPPA.

Paramètres	Valeurs
PSNR	70.2325
RLNE	0.1496
MSSIM	0.9999
Temps	210.769 s



(a)



(b)

**Figure III-6 :** (a) Image réelle de référence, (b) image reconstruite par la méthode GRAPPA.

- ✓ L'image obtenue a été jugée de bonne qualité, les paramètres d'évaluation obtenus ont été satisfaisants et le temps de calcul était raisonnable.

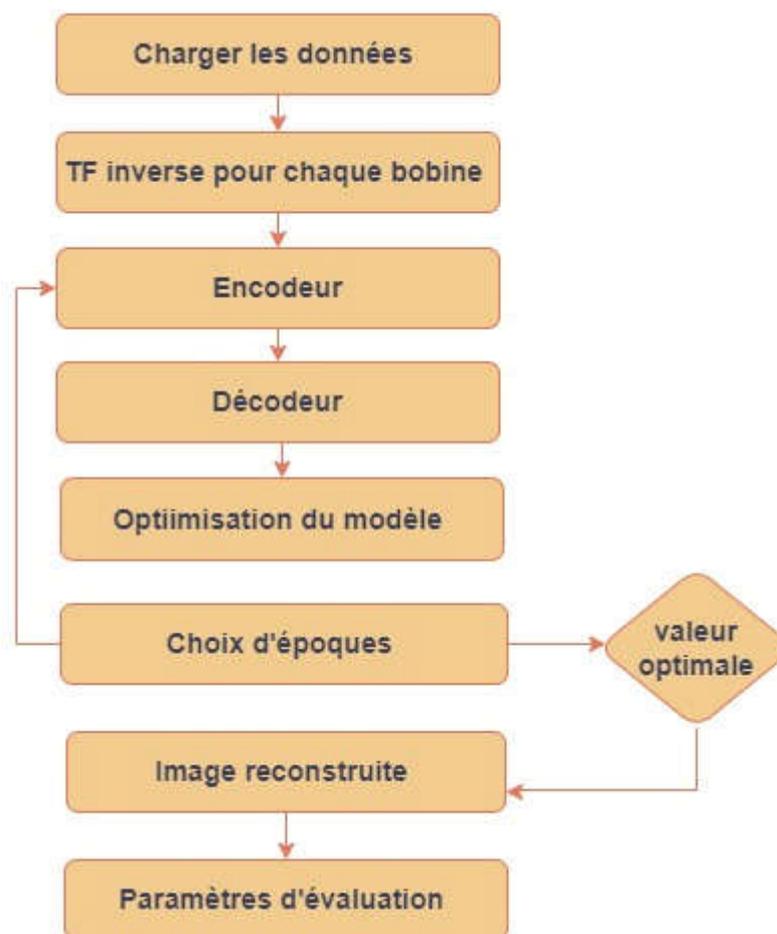
### 5.2 Algorithme CNN

L'algorithme CNN est une autre méthode très utilisée actuellement dans le domaine de traitement d'image. Pour cela nous avons choisi cette dernière et nous l'avons adapté à notre domaine de recherche. La section suivante explique comment nous avons adapté l'algorithme CNN à la reconstruction d'image :

- Charger les données d'espace k pour chaque bobine.
- Effectuer la transformée de Fourier inverse 2D pour chaque bobine.
- Convertir les données en un tenseur PyTorch.
- Normaliser les valeurs des pixels du tenseur entre 0 et 1 en les divisant par 255.
- remodeler le tenseur en une forme adaptée à la taille d'entrée .

- Implémenter une auto encodeur.
- Définir le réseau encodeur qui prend une image en entrée et la convertit en vecteur, avec des couches linéaires et une fonction d'activation ReLU.
- Définir le réseau décodeur qui prend le vecteur et le convertit en une image avec des couches linéaires et une fonction d'activation sigmoïde.
- Créer un optimiseur Adam avec les paramètres de l'autoencodeur, pour mettre à jour les poids du modèle pendant l'entraînement.
- Choisir le nombre d'époques.
- Répéter les opérations jusqu'à l'obtention d'une image reconstruite de bonne qualité.

Le diagramme de la **Figure III-7** explique les différentes étapes suivies :



**Figure III-7:** Organigramme de la méthode de reconstruction CNN.

Nous avons testé cet algorithme sur deux types d'images : image fantôme et image réelle. Pour les différentes applications, nous avons choisi un nombre d'époques de 900.

### 5.2.1 Reconstruction CNN sur l'image fantôme :

La **Figure III-8b** représente l'image fantôme reconstruite par l'algorithme CNN à partir des données fantôme représentées sous forme d'image par la **Figure III-5a**. Le tableau (**III-3**) représente les paramètres d'évaluation obtenus à partir de l'image reconstruite.

**Tableau III-3** : Paramètres d'évaluations obtenus à partir de l'image fantôme reconstruite par la méthode CNN.

Paramètres	Valeurs
PSNR	68.7695
RLNE	0.0116
MSSIM	0.9999
Temps	3.109 s



(a)



(b)

**Figure III-8** : a) Image fantôme de référence, (b) image reconstruite par la méthode CNN.

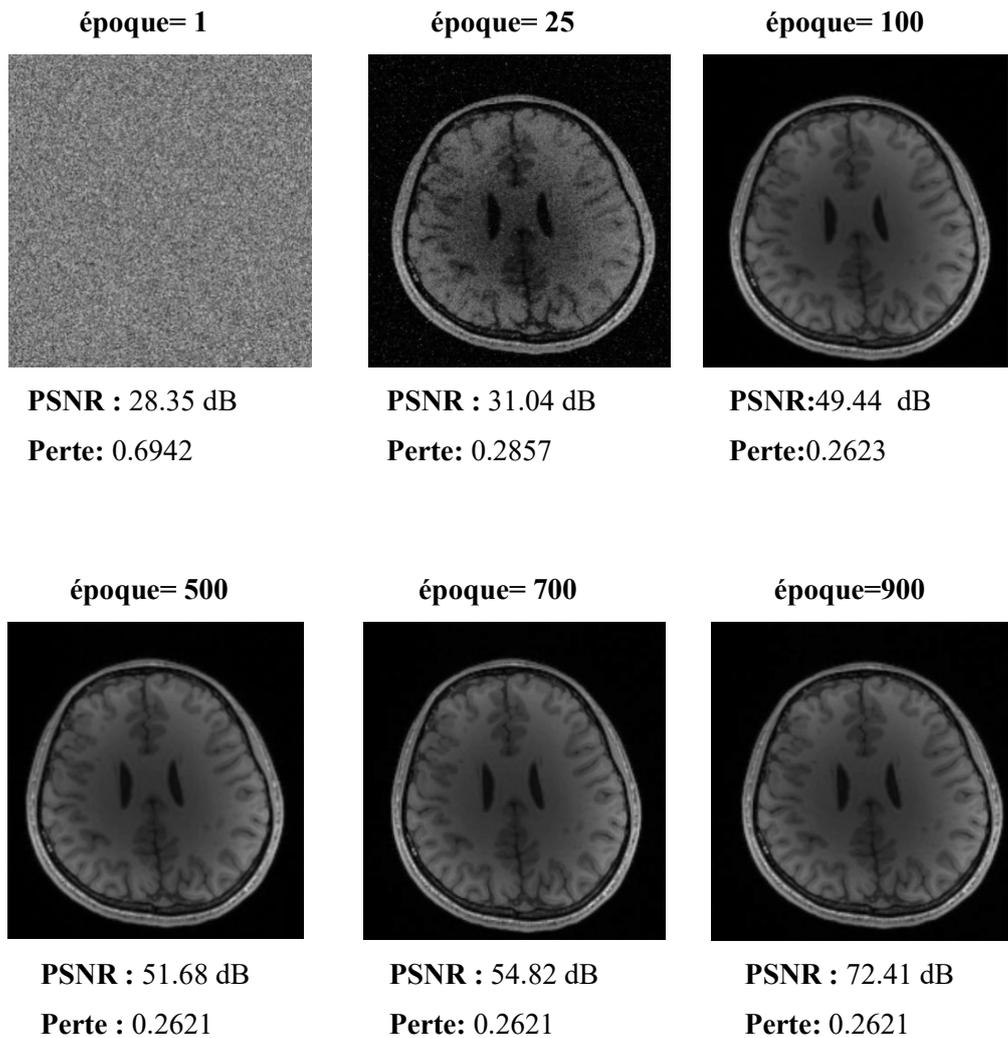
- ✓ L'image reconstruite par l'algorithme CNN présente une excellente qualité, avec des paramètres d'évaluation satisfaisants tels qu'une valeur élevée de PSNR, un MSSIM très proche de 1 et une faible valeur du RLNE par rapport à la méthode GRAPPA (voir le tableau 1). En plus, le temps de reconstruction se réduit.

### 5.2.2 Reconstruction CNN sur les données réelles :

Dans l'algorithme CNN, le nombre d'époques correspond au nombre de cycles complets pendant lesquels le modèle est entraîné sur l'ensemble de données. À chaque cycle, les poids

du modèle sont mis à jour et la précision est améliorée, et une fois que les cycles sont terminés, un modèle prêt à l'emploi est obtenu.

Dans nos applications, nous avons testé différents nombres d'époques afin d'obtenir une image de qualité souhaitée, la Figure (III-9) représente les résultats 'qualitatifs et quantitatifs' obtenus pour les différents nombres d'époques. Les résultats quantitatifs sont représentés à ce niveau par « PSNR et perte ».



**Figure III-9:** Résultats de reconstruction de données réelles obtenus suite au réglage du nombre d'époques.

Dans l'algorithme CNN, nous avons utilisé le paramètre "Perte" qui fait référence à la valeur d'erreur calculée pendant le processus d'entraînement. Cette valeur indique la différence entre l'image restaurée par le modèle et l'image d'origine ; elle est utilisée pour évaluer les performances du modèle et ajuster les paramètres d'entraînement afin de minimiser l'erreur.

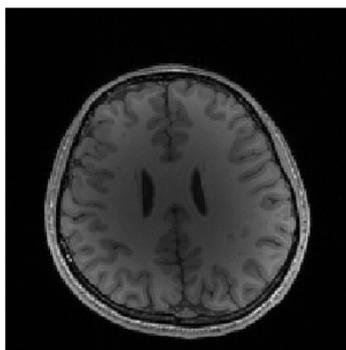
- ✓ Après avoir examiné les performances du modèle pour différentes valeurs du nombre d'époques (voir la figure (III-9)), nous avons constaté que les résultats obtenus à un nombre d'époques proches à 900 étaient de plus haute qualité.
- ✓ En effet, à cette valeur d'époque, le modèle a réussi à reconstruire l'image avec une grande précision, ce qui indique que le modèle était capable d'apprendre les caractéristiques importantes des données d'entraînement.

Afin de quantifier la précision de la reconstruction CNN, nous avons calculé les paramètres d'évaluation de l'image reconstruite.

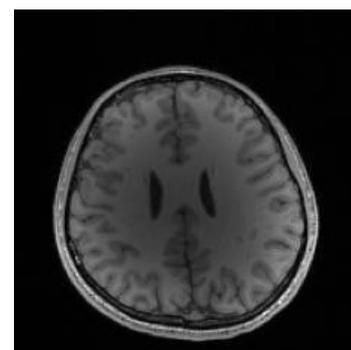
Le tableau (III-4) et la figure (III-10) représentent respectivement les paramètres d'évaluation et l'image reconstruite en utilisant la méthode CNN.

**Tableau III-4 :** Paramètres d'évaluations obtenus à partir de l'image réelle reconstruite par la méthode CNN

Paramètres	Valeurs
PSNR	72.41
RLNE	0.0174
MSSIM	0.9999
Temps	4.568 s



(a)



(b)

**Figure III-10:**(a) Image originale, (b) image reconstruite par la méthode CNN.

- ✓ Les résultats montrent que l'image reconstruite présente une qualité très proche de l'image originale, avec des paramètres satisfaisants tels qu'un PSNR élevé, une RLNE réduite et un temps de reconstruction réduit.

### 6. Algorithme proposé

La reconstruction GRAPPA est une méthode de reconstruction d'image largement utilisée par les applications médicales en raison de sa capacité à produire des images de haute qualité dans un temps d'acquisition court. L'apprentissage profond a introduit de nouvelles approches pour la reconstruction d'image en exploitant la puissance des réseaux de neurones. Les réseaux de neurones profonds peuvent apprendre à reconstruire des images IRM à partir de grandes quantités de données d'entraînement.

A cet effet, nous avons proposé une nouvelle approche permettant d'améliorer la qualité d'image reconstruite par la méthode GRAPPA en utilisant l'algorithme CNN.

La figure (III-9) représente en détail les étapes suivies pendant la reconstruction d'image en utilisant notre approche.

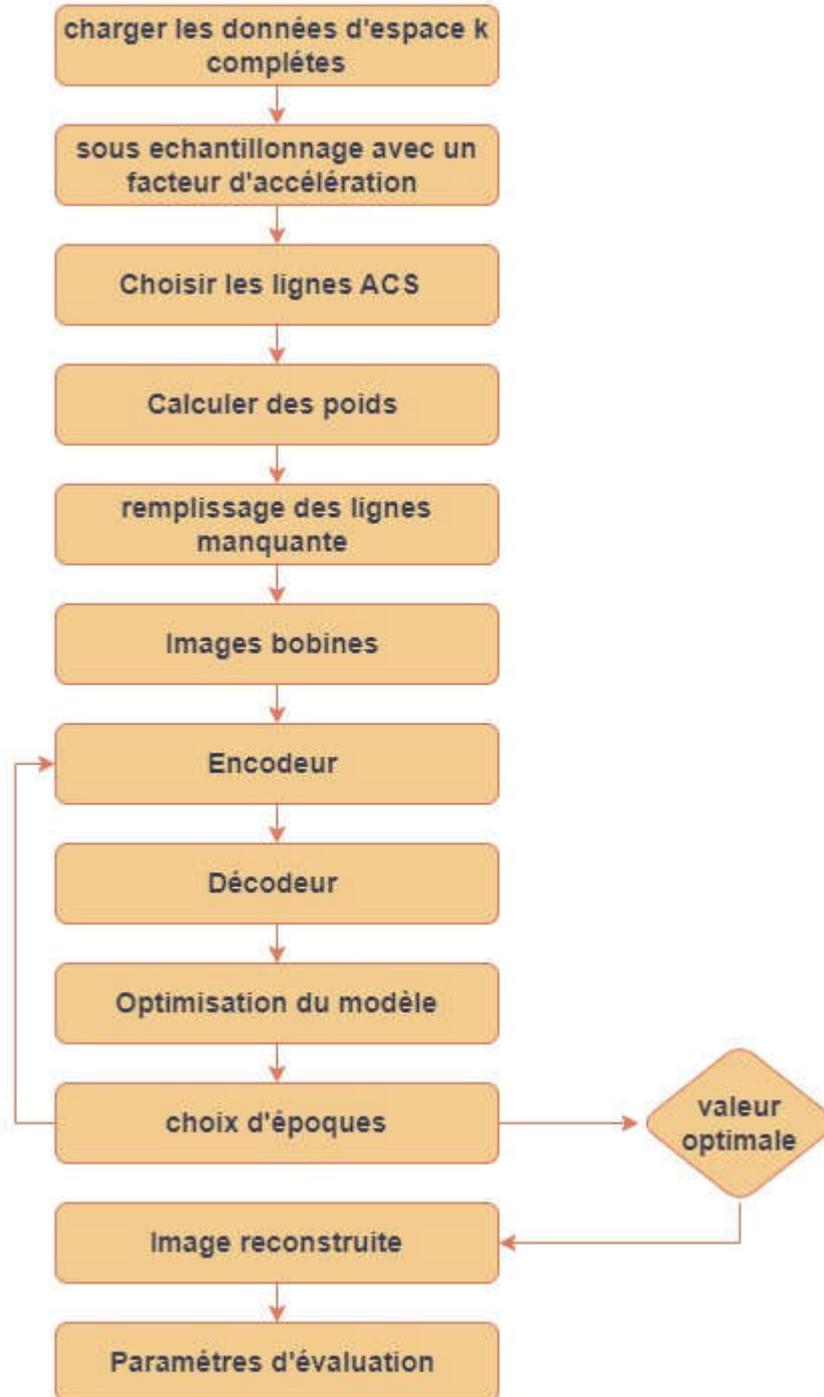


Figure III-11: Organigramme d'algorithme proposé.

Afin d'étudier les performances de notre algorithme, nous avons passé par différents test en utilisant des données fantôme et réelles.

Pour les différentes applications, nous avons choisi un facteur d'accélération  $R=2$ , un nombre de lignes ACS de 32, différents nombres de bobines '8 et 32', un nombre d'époques de 900 .

### 6.1 Reconstruction de notre approche sur l'image fantôme

En suivant toutes les étapes de notre algorithme, l'image reconstruite à partir des données fantôme est représentée par la figure (III-12b).

Les résultats des paramètres d'évaluation sont représentés sur le tableau (III-5).

**Tableau III-5** : Paramètres d'évaluations obtenus à partir de l'image fantôme reconstruite par notre approche.

Paramètres	Valeurs
PSNR	69.7386
RLNE	0.01038
MSSIM	0.9999
Temps	3.246 s



(a)



(b)

**Figure III-12:**(a) Image fantôme originale, (b) image reconstruite par notre approche.

- ✓ Les résultats qualitatifs et quantitatifs ont montré que l'image reconstruite par notre approche est de très bonne qualité, avec un PSNR élevé, MSSIM proche de 1 et un RLNE réduit par rapport à celle reconstruite par GRAPPA (voir le tableau III-1). Ainsi, le temps d'acquisition est relativement court.

### 6.2 Reconstruction de notre approche sur des données réelles

Afin d'étudier l'efficacité de notre algorithme, nous avons passé par différentes applications sur différents types de données réelles du cerveau. Nous avons commencé notre application

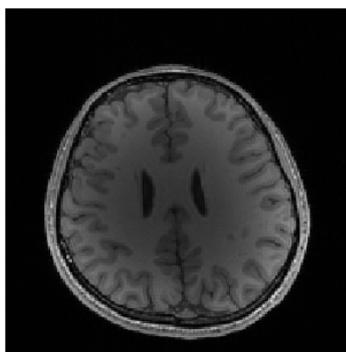
sur les données d'image obtenue d'une bobine 32 canaux utilisés dans les applications précédentes.

#### a- Données '32 canaux' :

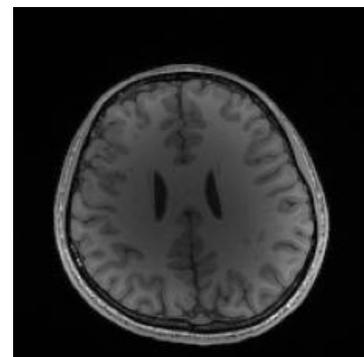
Le Tableau (III-6) représente les résultats des différents paramètres d'évaluation obtenus à partir de l'image reconstruite par notre approche. La Figure (III-13b) illustre l'image reconstruite à partir des données représentées par la figure (III-13a).

**Tableau III-6 :** Paramètres d'évaluations obtenus à partir de l'image réelle reconstruite par notre approche.

Paramètres	Valeurs
PSNR	71.3264
RLNE	0.0096
MSSIM	0.9999
Temps	4.616 s



(a)



(b)

**Figure III-13:** Image originale réelle (a) et image reconstruite par notre approche (b).

- ✓ Les résultats qualitatifs et quantitatifs ont montré que notre approche est performante par rapport à la méthode GRAPPA. L'image reconstruite est de haute qualité, les paramètres d'évaluation sont significativement améliorés (le tableau III.2) et le temps de reconstruction est considérablement réduit.

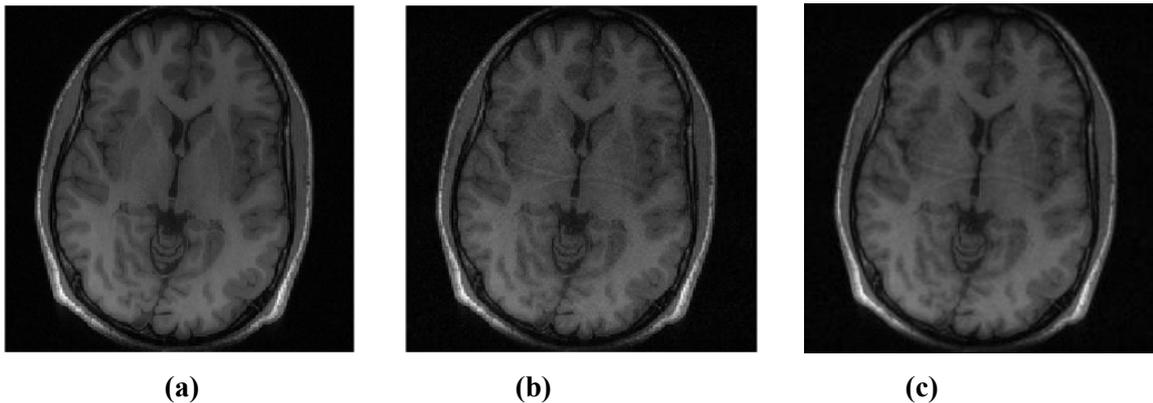
Nous avons continué nos applications sur deux autres types de données réelles 'brain et brain alias' tout en les comparant avec les images reconstruite par la méthode GRAPPA.

**b- Données 'brain\_8ch' :**

Les résultats des différents paramètres d'évaluation obtenus à partir des images reconstruites par la méthode GRAPPA et notre approche sont représentés sur le tableau (III-7). Les images reconstruites sont illustrées par la figure (III-14c).

**Tableau III-7 :** Paramètres d'évaluations obtenus à partir des images brain\_8ch reconstruite par la méthode GRAPPA et notre approche.

Paramètres	GRAPPA	Notre approche
PSNR	62.2181	71.6414
RLNE	0.3746	0.0076
MSSIM	0.9990	0.9999
Temps	9.601 s	4.051 s



**Figure III-14:** (a) Image originale, (b) image reconstruite par la méthode GRAPPA, (c) image reconstruite par notre approche.

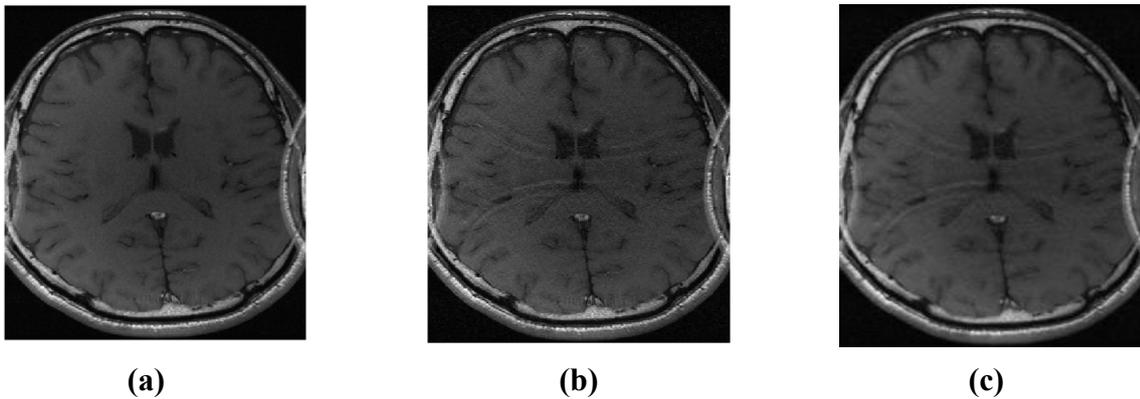
**c- données 'brain\_alias\_8ch' :**

Les données 'brain\_alias' représente des données acquises d'une manière repliée sur ses extrémités et ceci est due au champ de vue qui est réduit par rapport à la taille de l'image.

Les résultats des différents paramètres d'évaluation obtenus à partir des images reconstruites par la méthode GRAPPA et notre approche sont représentés sur le tableau (III-8). Les images reconstruites sont illustrées par la figure (III-15c).

**Tableau III-8 :** Paramètres d'évaluations obtenus à partir des images brain\_alias\_8ch reconstruite par la méthode GRAPPA et notre approche.

Paramètres	GRAPPA	Notre approche
PSNR	27.0320	46.8014
RLNE	0.0778	0.0121
MSSIM	0.7341	0.9918
Temps	23.213s	3.787 s



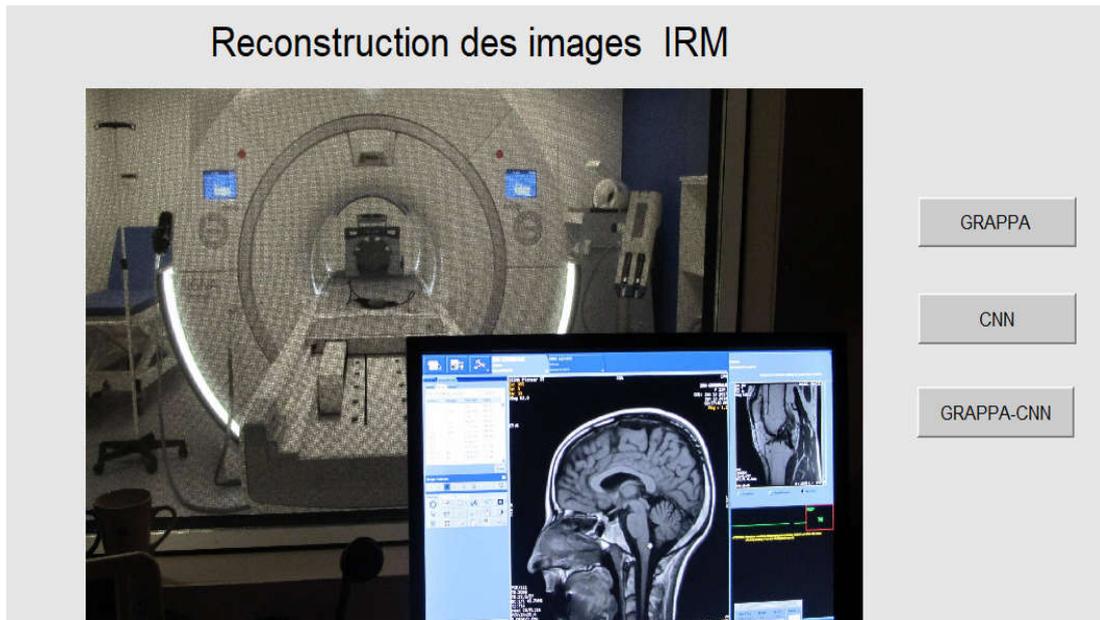
**Figure III-15:**(a) Image originale, (b) image reconstruite par la méthode GRAPPA, (c) image reconstruite par notre approche.

- ✓ A partir de différentes applications, nous avons constaté que l'image reconstruite par notre approche présente une meilleure qualité.
- ✓ En examinant les résultats des paramètres d'évaluation (indiqués sur les tableaux III-6, 7 et 8), nous avons confirmé que notre approche est améliorée par rapport à la reconstruction GRAPPA, avec un PSNR élevé, un MSSIM très proche de 1 un RLNE réduit.

Les résultats ont aussi montré que malgré le repliement et la faible qualité des données originaux, la reconstruction d'image par notre approche a permis d'améliorer significativement la qualité d'image.

### 7. Développement d'une interface graphique

Afin de faciliter l'acquisition d'images à partir des données IRM et afin de comparer les performances de la qualité d'image obtenue par différentes méthodes de reconstruction telles que GRAPPA, Deep Learning ou notre approche, nous avons réalisé une interface graphique homme machine capable d'accomplir tous ces besoins. La **Figure III-16** représente l'interface d'accueil.



**Figure III-16** : Interface d'accueil

Pour garantir le bon fonctionnement de notre interface, nous avons testé différentes applications.

Les figures (III-17), (III-18) et (III-19) illustrent respectivement les différentes interfaces permettant la reconstruction d'image par les méthodes GRAPPA, Deep Learning et notre approche.

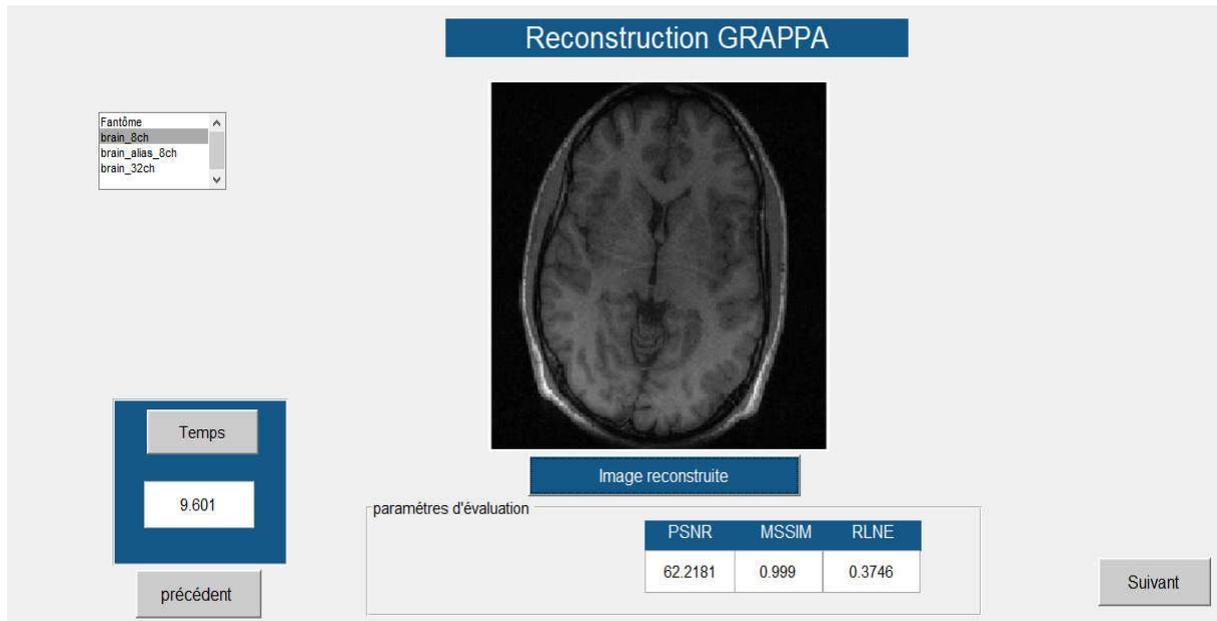


Figure III-17: Interface de reconstruction GRAPPA.

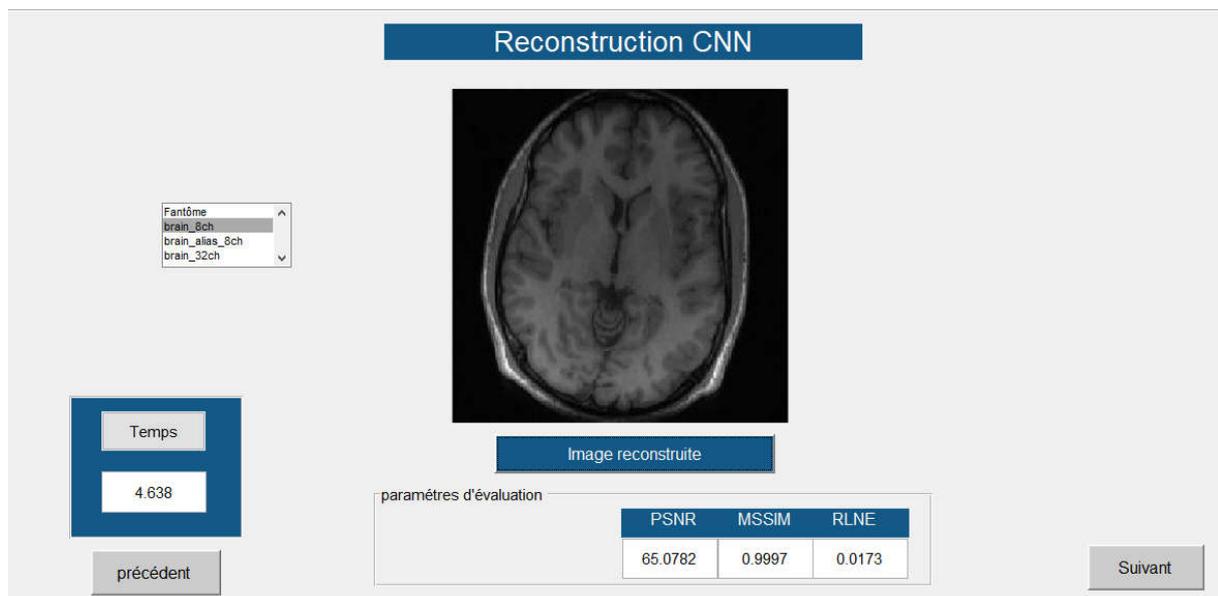
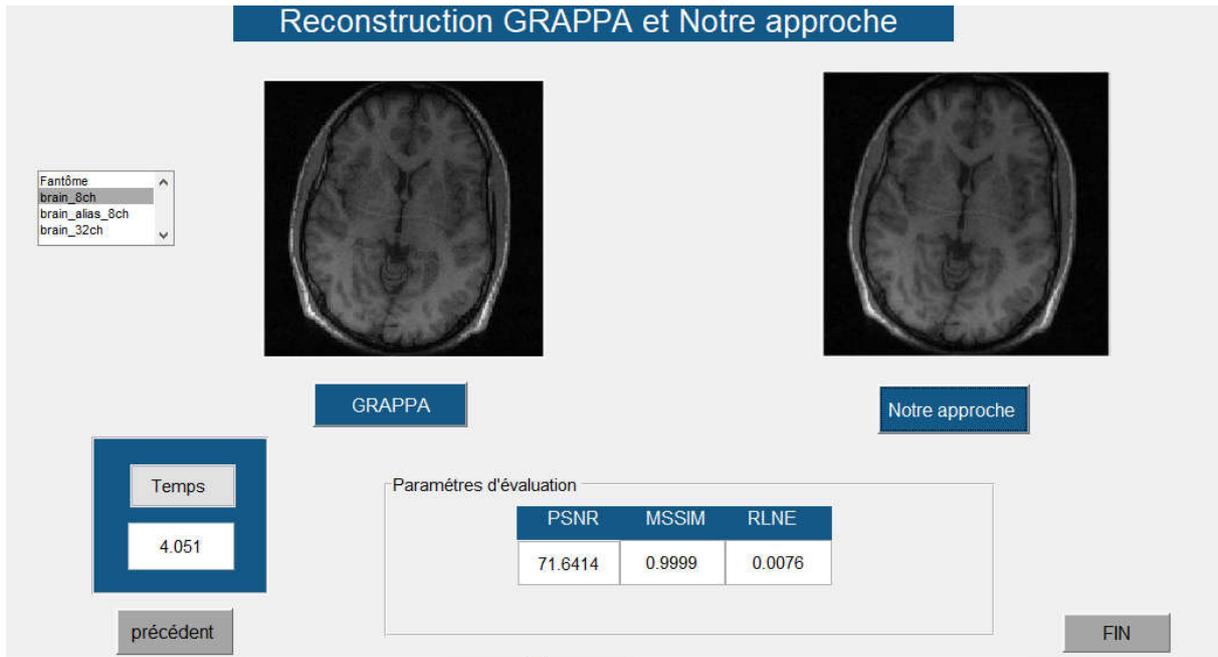


Figure III-18 : Interface de reconstruction par CNN.



**Figure III-19:**Interface de reconstruction par notre approche.

L'exécution des différents algorithmes ont confirmé le bon fonctionnement des interfaces.

Les résultats de chaque approche sont similaires à ceux trouvés dans les sections précédentes.

### 8. Conclusion

Dans notre projet fin d'étude, nous avons proposé d'améliorer la reconstruction GRAPPA par l'algorithme CNN qui est récent, très efficace et très utilisé par les chercheurs. Les résultats de reconstruction par notre approche paraissent très efficaces avec des images reconstruites de meilleure qualité et un temps d'acquisition réduit. Pour l'aide au diagnostic, nous avons aussi proposé de réaliser une interface graphique capable d'acquies des images IRM reconstruites par les trois méthodes : GRAPPA, CNN et notre approche. Les résultats ont montré que notre interface paraîtra utile dans le domaine d'IRM et notre approche peut être considérée comme une alternative prometteuse pour une reconstruction efficace et rapide.

## CONCLUSION GENERALE

L'imagerie parallèle est une technique avancée d'imagerie médicale qui a permis une amélioration significative de la qualité et de la rapidité de la reconstruction d'images IRM. Dans ce contexte, l'objectif primordial consiste à améliorer la reconstruction GRAPPA, qui bien qu'étant une méthode efficace, présente certaines limites en termes de qualité d'image. Pour résoudre ces problèmes, nous proposons de la rénover en se basant sur une méthode plus moderne et plus efficace, à savoir les réseaux de neurones convolutifs (CNN).

Dans notre projet fin d'étude, nous avons étudié deux méthodes récentes : GRAPPA et CNN. Nous avons testé les deux algorithmes sur une image fantôme ainsi que sur des données réelles provenant d'une bobine 32 canaux. Les résultats ont été encourageants. Cependant, la reconstruction GRAPPA a noté un temps de reconstruction un peu plus lent. Les résultats de la CNN ont montré une amélioration qualitative et quantitative avec un temps d'acquisition réduit.

Ces résultats suggèrent que la méthode CNN pourrait présenter une alternative prometteuse pour améliorer à la fois la qualité et la rapidité de la reconstruction d'images IRM. Pour ces raisons, nous avons appliqué la méthode CNN à la reconstruction GRAPPA. Les images reconstruites par notre approche proposée paraissent de meilleure qualité avec un PSNR très élevées par rapport à la méthode GRAPPA, ainsi, le temps de reconstruction est très court. En plus, il est important de noter que les résultats de notre approche ont été particulièrement remarquables pour les données repliées.

Les résultats obtenus ont prouvé que la reconstruction par notre approche offre des perspectives passionnantes pour l'amélioration de l'imagerie parallèle.

## LES PERSPECTIVES

Les perspectives de notre travail sont les suivants :

1. Appliquer d'autres architectures plus avancées et des techniques d'apprentissage auto-supervisées.
2. Utilisation de données multimodales : Les méthodes de reconstruction d'images IRM parallèle pourraient être améliorées en utilisant des données multimodales provenant de différentes modalités d'imagerie, telles que la scintigraphie et la tomographie.
3. Réaliser un logiciel plus performant conçu pour l'aide au diagnostic.

# BIBLIOGRAPHIE

- [1] J .Bittoun, « éléments constitutifs d'un appareil d'IRM », Volume 85, Septembre 2004, Page 1191.
- [2] Kadiri Nour El Houda, « Reconstruction d'images de Résonance Magnétique en imagerie parallèle », mémoire de projet fin d'études, le 22 juin 2013.
- [3] Chelihi Abderrahmane et Djemai Assia, « reconstruction adaptative pour l'imagerie par résonance magnétique parallèle des organes », mémoire de projet fin d'études, 23 mai 2016.
- [4] Iles Amel, «contribution à l'amélioration de méthodes d'acquisition parallèles appliquées à la reconstruction d'images IRM», thèse de doctorat, Décembre 2015.
- [5] Guillaume Madelin, « Développements méthodologiques de l'IRM à bas champ : Elastographie, Interaction IRM-Ultrasons et Polarisation Dynamique Nucléaire », thèse de doctorat ,2005 .
- [6] D. Canet, « la RMN : Concepts, méthodes et applications »,2002.
- [7] Bruno Van Oystaeyen, « Imagerie par résonance magnétique (IRM) », 12 septembre 2018.
- [8] Behissa Rayanne, « L'INSTALLATION L'APPAREIL MEDICAL IRM 1.5 TESLAS SIGNA CREATOR », mémoire de projet fin d'études, 2021.
- [9] B. Kastler, D. Vetter, « Codage spatial du signal et mise en place des événements d'une séquence IRM » ,17 Juin 2017.
- [10] Centre d'IRM Fonctionnelle Cérébrale de Marseille – <http://irmfmrs.free.fr> Muriel ROTH.
- [11] Deep Residual-ASPP Generative Adversarial Network for CS-MRI Reconstruction.
- [12] Santiago Aja-Fernández ; Gonzalo Vegas-Sánchez-Ferrero, « le livre : Statistical Analysis of Noise in MRI » , 13 juillet 2016 , page 9–29.
- [13] Pruessmann-Klaas, et al, « SENSE: Sensitivity encoding for fast MRI », Volume 42, 1999, page 952 – 96

- [14] Curatolo Calogero, « Recent advances in Parallel Imaging for MRI », Volume 4 ,11 janvier 2022.
- [15] Jinhua Sheng , et al, « Improved parallel magnetic resonance imaging reconstruction with multiple variable density sampling » , volume 11 , 26avril 2021, page 1\_15.
- [16] Khanh T. K. Nguyen, et al, « A Comparison Study of GRAPPA and Generalized Series Methods for parallel MRI at high acceleration factor », Novembre 2019, page 18-21.
- [17] Joseph Suresh Paul, et al, « Theory of Parallel MRI and Cartesian SENSE Reconstruction », volume651,4 juin 2016 ,page 311\_328 .
- [18] Omair Inam, et al, « GPU accelerated Cartesian GRAPPA reconstruction using CUDA »,Volume 337, Avril 2022.
- [19] Felix A. Breuer, et al, « General formulation for quantitative G-factor calculation in GRAPPA reconstructions » ,07 juillet 2009.
- [20] Yann LeCun, Yoshua Bengio & Geoffrey Hinton , « Deep learning », 27 Mai 2015
- [21] Mohamed Abd Elmoumen DJABALLAH, « Système de prédiction de la consommation d'énergie basé Deep Learning », Mémoire de Fin d'études Master, Septembre 2021.
- [22] Reuben Varghese Joseph, et al, « A hybrid deep learning framework with CNN and Bi-directional LSTM for store item demand forecasting » Volume 103, Octobre 2022.
- [23] Joseph Y. Cheng, et al, « Highly Scalable Image Reconstruction using Deep Neural Networks with Bandpass Filtering ».
- [24] MADADI Nacer YAHOUNI Billel, « Reconnaissance et classification des images par les Réseaux de Neurone », Mémoire de Fin d'études Master,2022.
- [25] J.R.R. Uijlings, K.E.A. Van de Sande, T. Gevers, A.W.M. Smeulders, « Selective Search for Object Recognition » ,2013.
- [26] Laith Alzubaidi, « Review of deep learning: concepts, CNN architectures, challenges, applications, future directions ».
- [27] Kerstin Hammernik,« Learning a variational network for reconstruction of accelerated MRI data », 08 Novembre 2017.

- [28] Deniz Kocanaogullari, et al, « Deep Learning For Mri Reconstruction Using A Novel Projection Based Cascaded Network » ,2019.
- [29] Yakkundi, Shashidhar « Convolutional LSTM: A Deep learning approach for Dynamic MRI Reconstruction » ,2020 .
- [30] Zexia Zhang, et al, « Time-Averaged Wind Turbine Wake Flow Field Prediction Using Autoencoder Convolutional Neural Networks », 22 Décembre 2021.
- [31] Dr. Oleksiy Khriyenko, « AutoEncoders and Convolutional Neural Networks (CNN) »,2023.
- [32] Judith Herrmann MD, et al, « Deep Learning MRI Reconstruction for Accelerating Turbo Spin Echo Hand and Wrist Imaging: A Comparison of Image Quality, Visualization of Anatomy, and Detection of Common Pathologies with Standard Imaging » ,2023.
- [33] Worapan Kusakunniran, et al, « Fast MRI reconstruction using StrainNet with dual-domain loss on spatial and frequency spaces » ; 2023.
- [34] Abdul Basit, et al « Accelerating GRAPPA reconstruction using SoC design for real-time cardiac MRI »,2023 .
- [35] Guan Qiu Hong, et al « Dual-domain accelerated MRI reconstruction using transformers with learning-based undersampling »,2023.
- [36] Zongjiang Tu, et al, « K-space and image domain collaborative energy-based model for parallel MRI reconstruction », volume 99,2023.
- [37] Jijie Hane, et al, « Improved Parallel Magnetic Resonance Imaging Reconstruction with Sampling based on Normal Distribution », Journal of Imaging Science & Technology , volume 67 ,2023.
- [38] Ruizhi Hou, Fang Li, « IDPCNN: Iterative denoising and projecting CNN for MRI reconstruction », Journal of Computational and Applied Mathematics, volume 406, 14 Décembre 2021.
- [39] Jinhong Huang, et al, « Evaluation on the generalization of a learned convolutional neural network for MRI reconstruction » ,2022.

[40] Mehmet Akçakaya, et al, « Scan-specific robust artificial-neural-networks for k-space interpolation (RAKI) reconstruction: Database-free deep learning for fast imaging »,18 Septembre 2018.

[41] ALIANE KAMILA, «Analyse numérique des résonateurs BCR, STR et SER inhomogènes. Application à la conception de sondes IRM », THESE DE DOCTORAT EN ELECTRONIQUE ,2012 .

[42] Karl Edler, « Spherical Harmonic Detection Coils and Dynamic Preemphasis », Mai 2010.

[43] Braikia Oussama et Bouchouicha Nadir, « Étude et implémentation d'un réseau de neurones convolutif CNN sur FPGA », mémoire de projet fin d'études ,2020.

[44] Logiciel Python.

[45] Logiciel Matlab.

[46] <https://mriquestions.com/grappaarc.html>.

[47] M. Lustig, D.L Donoho, J.M Santos and J.M Pauly « Compressed Sensing MRI »,Journal of Signal Processing Magazine, 2008, 25(2) ,page 72-82