REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE YAHIA FARES DE MEDEA



Faculté de Technologie
Département du Génie Electrique

Mémoire de fin d'études de Master

Filière : génie électrique

Spécialité : Systèmes des télécommunications

Amélioration de la qualité de service dans les réseaux mobile par le transfert d'apprentissage et analyse prédictive.

Présentés par :

Skender Mohamed Abdellah

Rebouh Younes

Proposés et Dirigés par :

Dr. LACHENANI Sid Ahmed

Co-promoteur :

Dr. Hamza khadar

Promotion 2024

Remerciement

Avant tout, nous remercions DIEU, le tout puissant, qui nous donnela volonté, la santé et la patience durant ces longues années d'étude afin que nous puissions Réaliser nos objectifs.

Tout d'abord, nous tenons à exprimer ma profonde gratitude à notre cher professeur et encadrant **Mr. LACHENANI Sid Ahmed** pour son suiviet pour son énorme soutien, qu'il n'a cessé de nous prodiguer tout au Lang de la période du projet. Je remercie également mes parentspour le grand soutien qu'ils M'ont apporté tout au long de mon parcours.

Enfin, nos remerciements à tous ceux qui ont contribué de près ou de loin au bon déroulement de ce projet. A tous mes amis de la section télécommunication, promos 2019-2024.

Merci à tous

Dédicaces

Avant tout, je tiens à remercier le bon Dieu, l'unique qui m'offre le courage et la volonté nécessaires pour affronter les différentes difficultés de la vie.

Je dédie ce modeste travail :

À mes très chers parents, source de vie, d'amour et d'affection. Mon père **Abdenour** et ma mère **Zineb**, que je n'arriverai jamais à exprimer ma gratitude et ma reconnaissance, pour leurs amours, leurs soutiens tout au long de mes études, leurs prières et leurs encouragements. Aucune dédicace ne pourra compenser leur sacrifice pour mon bien-être et mon bonheur.

À la famille **skender**, surtout mes frères et sœurs : **Hicham** et **Rekia**, sources de joie et de bonheur.

À tous mes amis et collègues.

En particulier à mes amis qui n'ont jamais manqué de me soutenir dans mon travail.

À notre encadreur **Mr. Lachenani Sid Ahmed** pour son immense patience, sa grande disponibilité et ses conseils qui ont grandement contribué à la réalisation de ce travail. Qu'il trouve ici l'expression de ma profonde gratitude.

À vous, cher lecteur.

Et à tous ceux qui nous ont soutenus pour l'achèvement de ce projet avec réussite.

Abdellah

Dédicaces

Avant tout, je tiens à remercier le bon dieu, et l'unique qui m'offre le courage et la volonté nécessaire pour affronter les différentes difficultés de la vie.

Je dédie ce modeste travail :

A mes très chers parents, source de vie, d'amour et d'affection Mon père **Kamel**, et ma mère **ghania**, que je n'arriverai jamais à exprimer ma gratitude et ma reconnaissance, pour ses amours ses soutiens tout au long de mes études et leurs prières, leur encouragement et qu'aucune dédicace ne pourra compenser leur sacrifice pour mon bien être et mon bonheur.

À la famille **Rebouh** surtout Mes sœurs et Mes frères : **Sara, Maria** et **Youcef** sources de joie et de bonheur.

À tous mes amis et collègues.

À notre encadreur **Mr. Lachenani Sid Ahmed** pour son immense patience, sa grande disponibilité et ses conseils qui ont contribué grandement à la réalisation de ce travail. Qu'il trouve ici l'expression de ma profonde gratitude

À vous cher lecteur

Et à tous ceux qui nous ont soutenus pour l'achèvement de ce projet avec réussite.

Younes.

Abstract:

With the advancement of automation and artificial intelligence tools, our dependence on machines has significantly increased. Today, many human functions operate independently without human interference. This project focuses on enhancing telephone network services by designing expert systems and applying machine learning (ML) algorithms for automated operation.

However, a major challenge persists: much of the network problem-solving still relies heavily on human experts. To address this, we concentrated on leveraging data analysis tools to automate problem detection and resolution, aiming to elevate it to a deeper level. The primary objective is to automatically identify issues in the network without relying on expert knowledge.

To achieve this, we developed the LTE_TL_NET algorithm, which detects anomalies in a cellular network monitoring system by analysing the traffic generated by the control system itself. Our proposed algorithm utilizes transfer learning to tackle this issue by adapting a pre-trained network to our system. An experimental test on the real LTE database yielded a recognition rate of 99.68%, demonstrating promising results.

Keywords: Automation, Artificial Intelligence (AI), Machine Learning (ML), Expert Systems, Telephone Network Services, Automated Operation, Human Interference,
Network Problem-Solving, Data Analysis Tools, Anomaly Detection, LTE_TL_NET, Algorithm, Cellular Network Monitoring, Traffic Analysis, Transfer Learning, Pre-trained Network, Experimental Test, LTE Database, Recognition Rate.

ملخص:

مع التقدم في اتصالات وتقنيات الذكاء الاصطناعي، زاد اعتمادنا على الآلات بشكل كبير. اليوم، تعمل العديد من الوظائف البشرية بشكل مستقل دون تدخل الإنسان. يركز هذا المشروع على تعزيز خدمات شبكة الهاتف من خلال تصميم أنظمة متخصصة وتطبيق خوارزميات التعلم الآلي للتشغيل الآلي.

ومع ذلك، لا يزال هناك تحدٍ كبير قائم، حيث يعتمد جزء كبير من حل مشكلات الشبكة بشكل كبير على الخبراء البشريين. لمعالجة هذه المشكلة، ركزنا على الاستفادة من أدوات تحليل البيانات لاكتشاف المشكلات وحلها بهدف الارتقاء بها إلى مستوى أعمق.

الهدف الأساسي هو تحديد المشكلات في الشبكة تلقائيًا دون الاعتماد على معرفة الخبراء ولتحقيق ذلك، قمنا بتطوير خوارزمية التي تكتشف الحالات الشاذة في نظام مراقبة الشبكة الخلوية من خلال تحليل حركة المرور الناتجة عن نظام LTE_TL_NET التحكم نفسه.

تستخدم الخوارزمية المقترحة نقل التعلم لمعالجة هذه المشكلة من خلال تكييف شبكة مدربة مسبقًا مع نظامنا. وقد أسفر الاختبار الحقيقية عن معدل تعرف بنسبة 99.68%، مما يدل على نتائج واعدة. LTE التجريبي على قاعدة بيانات.

الكلمات المفتاحية: الذكاء الاصطناعي، التشغيل الآلي، خدمات شبكة الهاتف، أنظمة متخصصة،

أدوات تحليل البيانات, LTE_TL_NET, خوارزميات التعلم الآلي, نظام مراقبة الشبكة الخلوية, نقل التعلم, شبكة مدربة مسبقا, LTE,معدل التعرف, اعتماد على الآلات, الوظائف البشرية.

Résumés :

Avec l'avancement de l'automatisation et des outils d'intelligence artificielle, notre dépendance aux machines a considérablement augmenté. Aujourd'hui, de nombreuses fonctions humaines fonctionnent indépendamment sans interférence humaine. Ce projet met l'accent sur l'amélioration des services de réseau téléphonique par la conception de systèmes experts et l'application d'algorithmes d'apprentissage automatique (ML) pour le fonctionnement automatisé.

Toutefois, un défi majeur persiste : la résolution des problèmes de réseau repose encore en grande partie sur des experts humains. Pour y remédier, nous nous sommes concentrés sur l'utilisation d'outils d'analyse de données pour automatiser la détection et la résolution de problèmes, en vue de les élever à un niveau plus profond. L'objectif principal est d'identifier automatiquement les problèmes du réseau sans compter sur des connaissances spécialisées.

Pour ce faire, nous avons développé l'algorithme LTE_TL_NET, qui détecte les anomalies dans un système de surveillance réseau cellulaire en analysant le trafic généré par le système de contrôle lui-même. Notre algorithme proposé utilise l'apprentissage de transfert pour résoudre ce problème en adaptant un réseau pré-entraîné à notre système. Un test expérimental sur la base de données LTE réelle a donné un taux de reconnaissance de 99,68%, démontrant des résultats prometteurs.

Mots clés : Automatisation, Intelligence artificielle, Dépendance aux machines, Fonctions humaines indépendantes, Services de réseau téléphonique, Systèmes experts, Algorithmes d'apprentissage automatique (ML), Fonctionnement automatisé, Résolution des problèmes de réseau, Experts humains, Outils d'analyse de données, Détection de problèmes, Algorithme LTE_TL_NET, Surveillance réseau cellulaire, Analyse du trafic,Apprentissage de transfert,Réseau pré-entraîné,Base de données LTE,Taux de reconnaissance .

Table de matière

Table de matière :

INTRODUCTION GENIRALE

Chapitre I :

I.1- Introduction : ***1***

I.2- Le réseau mobile de deuxième génération : ***1***

I.2.1- Système de communication GSM : 2

I.2.1.1 -Architecture GSM : 2

I.2.1.2 -Interfaces GSM : 6

I.2.2 -Transmission radio GSM : 7

I.2.2.1- Les bandes de fréquences du réseau GSM : 7

I.2.2.2 -Techniques d'accès radio dans le GSM : 7

I.2.3 -Canaux logiques dans le GSM : 8

I.2.4-GPRS : 9

I.2.5-L'EDGE : 11

I.2.6 -Paramètres d'optimisation du réseau en 2G : 11

I.2.6.1 -Indicateurs clés de rendement dans le GSM : 11

I.2.6.2 -Principaux KPIs dans le GSM : 11

I.3- Le système de réseau mobile de troisième génération : ***13***

I.3.1- Réseau UMTS : 14

I.3.1.1 Architecture UMTS : 14

I.3.1.2 Le réseau d'accès radio : 14

I.3.1.3- Les techniques d'accès radio : 15

I.3.1.4- Contrôle de puissance : 15

I.3.1.5- Sélection de cellules : 16

I.3.2- Principaux paramètres et répartitions du spectre dans le réseau UMTS : 17

I.3.3- Canaux UMTS : 17

I.3.4- États du RRC : 17

I.3.4.1- Mode de connexion RRC : 19

I.3.5- Optimisation du réseau UMTS : 19

I.3.5.1- KPIs en UMTS : 19

I.3.5.2- Optimisation des KPIs : 21

I.4- Le système de réseau mobile de quatrième génération : ***23***

I.4.1- Vue d'ensemble du réseau LTE : 23

I.4.2- Architecture de réseau LTE : 24
I.4.3- Réseau d'accès radio dans LTE : 25
I.4.3.1-L'Union européenne : 25
I.4.3.2- L'E-UTRAN: 25
I.4.3.3- Réseau de base LTE: 25
I.4.4 Interfaces LTE : 27
I.4.5- Handover en LTE : 28
I.4.5.1- Mobilité inter-RAT : 28
I.4.5.2- Mobilité vers la eNodeBs : 29
I.4.5.3- Livraison sans faille : 29
I.4.5.4- Handover sans perte : 30
I.4.6- Type d'accès radio LTE : 30
I.4.7- Optimisation LTE et analyse KPI : 31
I.5- conclusion : 32
II.1-introduction : 33
II.2-Deep Learning : 33
II.2.1-Définition : 34
II.2.2-Historique : 35
II.2.3- Pour quoi le choix deep Learning : 36
II.2.4-Les différentes Architectures du Deep Learning : 37
II.2.4.1-Les réseaux de neurones convolutifs : 37
II.2.4.2 -Réseau de neurones récurrents : 38
II.2.4.3-Modèle génératif : 38
II.2.5- Exemples d'application de Deep Learning : 39
II.3- Machine Learning : 40
II.4- Transfer learning : 41
II.4.1- Histoire du Transfer Learning: 42
II.4.2- Comment utiliser l'apprentissage par transfert : 43
II.4.3- Type de Transfer Learning: 44
II.4.4- Méthodes d'évaluation des réseaux IA : 46
II.4.5- Matrice de confusion : 46
II.4.6- Métriques d'évaluation : 46
II.4.7-Courbes d'évaluation : 48
II.4.7.1-La courbe de rappel de précision : 48
II.5-Conclusion : 49
III.1- Introduction : 51
III.1.1 Motivation : 51

III.1.2 Objective : 51
III.1.3- Exigences et performance: 52
III.2-Collecte des données et base de données : 53
III.2.1- Types de données utilisée (Dataset) : 53
III.2.2-Collecte des données : 54
III.2.3-Description de la base de données : 55
III.3-Expérimentations et discutions : 56
III.3.1- Solution avec deep learning : 56
III.3.1.1- processus d'entraînement du réseau de neurones : 56
III.3.1.2- Évaluation du réseau de neurones : 58
III.3.1.3-la matrice de confusion : 59
III.3.1.4-Métriques d'évaluation du DL: 60
III.3.2-Solution avancée avec Deep Learning (avec la moyenne) : 61
III.3.2.1- Évaluation du réseau de neurones (avec la moyenne): 61
III.3.2.2-Matrice de confusion : 63
III.3.2.3-Métriques d'évaluation du DL: 63
III.3.3-Modèle proposé pour le Transfert Learning : 64
III.3.3.1-Matrice de confusion : 66
III.3.3.2-Métriques d'évaluation du TL: 66
III.4-Comparaison des résultats : 67
III.4.1-Résultats détaillés : 67
III.5-Comparaison avec des travaux antérieurs : 69
III.5.1-Travaux sur la détection d'anomalies dans les réseaux LTE : 69
III.5.2-comparison des travaux sur la détection d'anomalies : 70
III.6-Conclusion : 70
CONCLUSION GENERALE 71

Liste des figures

Chapitre I :

Figure I.1: Structure du numéro IMEI. 2
Figure I.2: Architecture globale du GSM et GPRS. 5
Figure I.3: Diagramme temps/fréquence des techniques d'accès. (b) TDMA, (a)FDMA. . 8
Figure I.4: Architecture de réseau UMTS connectée à un réseau hérité. 13
Figure I.5: Types de transfert dans le réseau UMTS. 16
Figure I.6: RRC connection establishment. 20
Figure I.7: Architecture de réseau LTE. 24
Figure I.8: piles de protocoles de l'utilisateur LTE. 28
Figure I.9: Inter-RAT mobility procedures. 29
Figure I.10: Type d'accès radio LTE. a) mode TDD, b) mode FDD. 31

Chapitre II :

Figure II. 1: Les sous-catégories de L'IA. 33
Figure II. 2: illustratif Schéma de DL avec plusieurs couches. 35
Figure II. 3: Comparaison entre la machine Learning et le Deep Learning. 37
Figure II. 4: Différents modèles du Deep Learning. 39
Figure II. 5: comparaison entre programme traditionnelle et machine learning. 41
Figure II. 6: Transfer Learning. 42
Figure II. 7 Type de transfert Learning. [51] 44
Figure II. 8 : Apprentissage inductif et transfert inductif. 45
Figure II. 9: Exemple d'une courbe PR. 48

Chapitre III

Figure III 1 : Architecture générale de l'acquisition de données 55
Figure III 2 : architecture du réseau de neurones DL. 57
Figure III.3: Évolution de la précision d'entraînement et de validation au cours des itérations. 58
Figure III.4: matrice de confusion (DL). 59
Figure III.5: Mesures de Performance d'un Modèle de Classification. 60
Figure III.6: Évolution de la précision d'entraînement et de validation au cours des itérations(avec la moyenne). 62
Figure III.7: Matrice de confusion (DL avec la moyenne). 62
Figure III.8: Mesures de Performance d'un Modèle de Classification 64
Figure III.9: Évolution de la précision d'entraînement et de validation au cours des itérations. 65
Figure III.10: Matrice de confusion(TL). 65
Figure III.11: Mesures de Performance d'un Modèle de Classification. 67
Figure III. 12 : Comparaison des performances. 69
Figure III.13 : comparison des travaux sur la détection d'anomalies 70

Liste des Tableaux

Chapitre I :

Tableau I.1: La plupart des canaux logiques dans le système GSM......10
Tableau I.2: La plupart des canaux logiques existants dans le système UMTS 18
Tableau I.3: Optimisation de l'appel-décharge CS. 20
Tableau I.4: Optimisation des appels PS......21
Tableau I.5: Optimisation de la défaillance de la connexion RRC. 21
Tableau I.6: Optimisation de la défaillance de HO. 22
Tableau I.7: Optimisation des défaillances de l'IRAT HO. 24
Tableau I.8: Optimisation de la congestion électrique......24
Tableau I.9: Différence entre le LTE-FDD [8].....30
Tableau I.10: KPI du RAN LTE. 31
Tableau I.10: KPI du RAN LTE. 32

Chapitre II :

Tableau II. 1: Matrice de confusion......46

Chapitre III :

Tableau III.1: Paramètres et Valeurs pour l'Optimisation du Modèle de Classification.
.....57

Liste des Abréviations

- 2G : Deuxième génération de téléphonie mobile
- 3G : Troisième génération de téléphonie mobile
- 4G : Quatrième génération de téléphonie mobile
- ADS : Anomaly Detection System
- CDMA : Code Division Multiple Access
- CN : Core Network
- CS : Circuit Switched
- CSV : Comma-Separated Values
- DL : Deep Learning (Apprentissage Profond)
- FDD : Frequency Division Duplex
- FDMA : Frequency Division Multiple Access
- HD : Haute Définition
- IA : Intelligence Artificielle
- KPI : Key Performance Indicator
- MATLAB : Matrix LABoratory
- ML : Machine Learning (Apprentissage Automatique)
- NET : Network
- NMT : Nordic Mobile Téléphone
- OMC : Operations and Maintenance Centre
- PLMN : Public Land Mobile Network
- PS : Packet Switched
- PSTN : Public Switched Telephone Network
- QOE : Quality of Experience
- QOS : Quality of Service
- RRC : Radio Resource Control
- SMS : Short Message Service
- SUR : Service Unavailable Rate
- TACS : Total Access Communication System
- TDD : Time Division Duplex
- TDMA : Time Division Multiple Access
- TL : Transfer Learning (Transfert d'Apprentissage)

- UMTS : Universal Mobile Télécommunications System
- WCDMA : Wideband Code Division Multiple Access

INTRODUCTION GENERALE

Introduction générale :

Les réseaux mobiles ont connu une évolution rapide et significative depuis leur création, transformant radicalement la manière dont nous communiquons et accédons à l'information. Cette évolution s'est déroulée en plusieurs générations, chacune apportant des améliorations notables en termes de capacité, de vitesse et de services offerts. La deuxième génération de réseaux mobiles 2G, lancée au début des années 1990, a marqué le passage des communications analogiques aux communications numériques. La 2G, principalement représentée par le GSM (Global System for Mobile Communications), a introduit de nombreuses innovations. Les services vocaux ont été considérablement améliorés avec une qualité de voix nettement meilleure par rapport aux réseaux analogiques. La troisième génération 3G, introduite au début des années 2000, a été conçue pour offrir des services multimédias et des connexions Internet mobiles rapides. Les technologies 3G, telles que UMTS (Universal Mobile Télécommunications System) et HSPA (High-Speed Packet Access), ont apporté des améliorations significatives. Les vitesses de données accrues ont permis la navigation sur Internet, la vidéoconférence et le streaming. Le support pour des applications telles que la télévision mobile, les jeux en ligne en streaming a été rendu possible grâce aux services multimédias avancés. De plus, la gestion améliorée des priorités de trafic a garanti la qualité des services critiques grâce à une meilleure qualité de service (QoS).

La quatrième génération 4G, introduite à la fin des années 2000, a encore amélioré la vitesse et la capacité des réseaux mobiles, permettant des expériences utilisateur proches de celles des réseaux filaires. La technologie clé de la 4G est le LTE (Long Term Evolution), qui a apporté plusieurs avantages. Les très hauts débits de téléchargement, pouvant atteindre plusieurs centaines de Mbps, ont permis des applications exigeantes en bande passante comme la vidéo HD et les jeux en ligne en temps réel. La latence réduite a amélioré les temps de réponse, essentiel pour les applications interactives et les services de cloud computing. La 4G a également augmenté la capacité des réseaux en supportant un plus grand nombre de dispositifs connectés, essentiel pour l'Internet des objets . De plus, l'adoption du protocole Internet (IP) pour toutes les communications a facilité l'intégration avec les réseaux de données existants.

Les réseaux mobiles ont également connu une nette amélioration des performances, et les opérateurs mobiles s'efforcent toujours d'atteindre une bande passante plus élevée, une latence moins importante, des connexions plus denses et une vitesse plus rapide.

Les opérateurs de réseaux mobiles sont confrontés à des défis sans précédent alors qu'ils se préparent à soutenir plus d'abonnes exigent en bande passante, un exploit qui souligne le rôle crucial des réseaux cellulaires Long-Term Evolution (LTE). Ces réseaux offrant des vitesses de transmission de données améliorées et une latence réduite par rapport à leurs homologues de troisième génération (3G).

Malgré leurs capacités, le fonctionnement des réseaux LTE comporte des difficultés, en particulier dans le domaine de la gestion des ressources radio. Les principaux défis découlent des coûts élevés et de la disponibilité limitée de ressources essentielles telles que le spectre de fréquences. La prolifération des appareils sans fil a aggravé ces problèmes, entraînant de graves congestion du spectre et des coûts d'exploitation élevés. Historiquement, les opérateurs ont géré le trafic de pointe en déployant plus de cellules macro et en sur provisionnant la capacité du réseau, une stratégie qui n'est plus viable en raison de ses lourds impacts économiques d'un point de vus ressources humains.

Face à ces défis, le développement des réseaux LTE, en particulier avec l'adoption des technologies de quatrième génération (4G), s'est orienté vers l'utilisation de l'apprentissage automatique (ML) pour une optimisation plus dynamique et efficace des ressources radio. Pour y parvenir, une approche d'apprentissage automatique est mise en œuvre pour détecter des comportements inhabituels dans l'utilisation du réseau, ce qui pourrait motiver une modification de la configuration de la station de base.

Cependant, le manque de données d'apprentissage est un problème majeur dans certains domaines spécifiques. La collecte de ces données est complexe et coûteuse, rendant difficile la création d'un ensemble de données annotées à grande échelle et de haute qualité. L'apprentissage par transfert atténue cette contrainte en ne nécessitant pas que les données d'entraînement soient indépendantes et identiquement distribuées (i.i.d.) par rapport aux données de test. Cette méthode permet de réduire considérablement les besoins en données d'apprentissage et le temps nécessaire à la formation dans le domaine cible, en réutilisant des modèles préexistants.

Nous avons développé des modèles de classification supervisée utilisant des données historiques de 4G LTE pour identifier et gérer les comportements cellulaires. Ces modèles distinguent les états de fonctionnement normaux des anomalies provoquées par des événements externes, comme des manifestations sportives ou des réunions sociales de grande envergure, susceptibles de perturber le réseau et nécessitant une réaffectation rapide des ressources.

Notre projet est structuré comme suit :

1. Le premier chapitre étudie les architectures et protocoles des réseaux mobiles 2G, 3G et 4G, offrant une vue d'ensemble de leur conception et optimisation.

2. Le deuxième chapitre décrit les technologies d'intelligence artificielle (IA), de machine Learning (ML), de Deep Learning (DL) et d'apprentissage par transfert.

3. Le troisième chapitre, cœur du projet, examine l'apprentissage par transfert, introduit principalement pour pallier le manque de données. Nous y réaliserons des expériences pour illustrer et justifier l'importance de cette méthode, démontrant sa capacité à résoudre des problèmes critiques, notamment en ce qui concerne la qualité des cellules mobiles.

CHAPITRE I :

I.1- Introduction :

L'évolution des réseaux mobiles a commencé avec la première génération (1G) dans les années 1980, utilisant des techniques de transmission analogique. L'absence de coordination internationale pour les normes a conduit à des déploiements régionaux tels que le NMT dans les pays nordiques et le TACS au Royaume-Uni et en Irlande, créant ainsi une incompatibilité entre ces systèmes. La demande croissante de communication mobile a conduit à la création de la deuxième génération (2G), qui visait à améliorer l'interopérabilité et à offrir des services améliorés, bien que les normes restassent variées selon les régions. Le GSM s'est imposé comme une norme mondiale, évoluant avec les services GPRS et EDGE pour permettre des transferts de données plus rapides, bien que limités par leur fonctionnement à commutation de circuit. Pour surmonter ces limitations, la 3G a vu le jour, représentée par l'UMTS, avec une norme mondiale IMT-2000 et une variante américaine, le CDMA2000. La technologie WCDMA a été adoptée pour l'interface radio, offrant une gamme étendue de services Internet et multimédias. L'évolution ultérieure a conduit à la LTE, ou 4G, visant à augmenter la vitesse, la capacité et à réduire la latence des réseaux mobiles. Alors que les réseaux évoluent vers un système tout-IP, la conception devient plus simple.[1]

Ce chapitre examine les architectures et les protocoles des réseaux mobiles 2G, 3G et 4G, afin d'offrir au lecteur une vue d'ensemble de leur conception et de leur optimisation.

I.2- Le réseau mobile de deuxième génération :

La 2G des téléphones mobiles numériques est arrivée dans les années 1990, marquant une croissance exponentielle dans les télécommunications mobiles. Le GSM, adopté comme norme mondiale, a été le premier système cellulaire numérique commercialisé en 1991. Il offrait des fonctionnalités telles que les appels prépayés, l'itinérance internationale et des services comme le courrier vocal et les SMS, ces derniers connaissant un énorme succès avec environ 15 milliards d'envois par mois en 2000. La norme ouverte du GSM a permis une interopérabilité facile, favorisant l'installation d'équipements de divers fournisseurs.

Du point de vue technique, le GSM utilisait une solution d'accès multiple à division temporelle à bande étroite (TDMA) avec le Gaussian Minimum Shift Keying (GMSK) comme stratégie de modulation. Son architecture comprenait plusieurs sous-systèmes, tels que le sous-système radio, le sous-système réseau et le sous-système d'opération et de maintenance (OMC). Les processus de transfert et d'itinérance étaient des aspects clés du réseau GSM, tout comme les itérations de 2G ultérieures telles que GPRS (General Packet Radio Service) et EDGE (Enhanced Data Rates for GSM Evolution).

La partie suivante examine en détail l'architecture du réseau GSM, ses sous-systèmes, les processus tels que le transfert et l'itinérance, ainsi que les itérations de 2G telles que GPRS et EDGE, en tenant compte des améliorations et de l'optimisation du réseau.[2].

I.2.1- Système de communication GSM :

La norme GSM a été inventée par ETSI pour décrire les protocoles de réseau numérique 2G utilisés par les terminaux tels que les téléphones mobiles. Au milieu des années 2010, il était devenu une norme mondiale pour les communications mobiles, s'étendant sur plus de 90% et établi dans 193 pays. [2].

I.2.1.1 -Architecture GSM :

Les principaux sous-systèmes 2G PLMN sont les suivants :

a) La station mobile (MS):

Il existe des entités spécifiques qui sont utilisées par les utilisateurs mobiles pour accéder à de nombreux services. Ces derniers sont composés d'un certain nombre de composants importants :

- **Équipement mobile (ME):**

Ou, comme on les appelle plus souvent, les téléphones portables, qui sont les seuls terminaux GSM qui permettent aux utilisateurs d'accéder au réseau GSM.

- **Module d'identité d'abonné (SIM) :**

donne une identité unique à l'équipement mobile. Certaines caractéristiques des abonnés ainsi que les données personnelles de l'abonné sont enregistrées sur la carte SIM. Les abonnés sont identifiés par la carte SIM du réseau. Avant d'utiliser le téléphone, les clients doivent saisir un numéro d'identification personnelle de 4 bits (PIN) pour protéger la carte SIM contre une utilisation non autorisée.

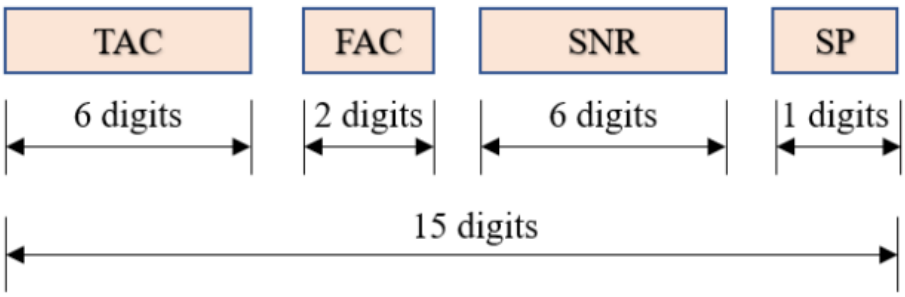


Figure I.1: Structure du numéro IMEI.

➢ **Numéro d'identification international d'équipement mobile (IMEI) :**

Il s'agit d'un numéro de série unique utilisé pour identifier les stations mobiles dans le monde entier. Le fabricant attribue l'IMEI, et les opérateurs de réseau le consignent dans le registre d'identification des équipements (EIR). L'IMEI est une adresse hiérarchique composée des éléments suivants :

- **Code d'homologation de type (TAC)** : Composé de six chiffres, il est généralement associé au modem ou au module cellulaire.
- **Code d'assemblage final (FAC)** : Identifie l'emplacement de la dernière étape de production et se compose de deux chiffres.
- **Numéro de série (SNR)** : Composé de six chiffres, il est attribué par le fabricant.
- **Chiffre de réserve (SP)** : Un seul chiffre. La figure 1 montre les principaux composants du numéro IMEI.

➢ **Identité internationale d'abonné mobile (IMSI) :**

Chaque abonné obtient une identification unique appelée IMSI lorsqu'il s'inscrit pour un service auprès d'un opérateur de réseau, enregistrée dans la carte SIM. L'équipement mobile avec un IMEI valide fonctionne correctement si la carte SIM avec un IMSI valide est insérée.

➢ **Numéro ISDN d'abonné mobile (MSISDN) :**

Le MSISDN est le numéro de téléphone réel de l'abonné. Il est attribué à l'abonné ; ainsi, un MS peut avoir plusieurs MSISDN en fonction de la carte SIM. L'association MSISDN et IMSI enregistrée dans le registre de localisation domestique (HLR) doit être connue avant que l'identification de l'abonné puisse être déduite du MSISDN.

➢ **Numéro de station mobile en itinérance (MSRN) :**

C'est un numéro temporaire du réseau numérique de services intégrés (ISDN) qui change en fonction de l'emplacement.

Il est attribué à chaque MS dans son territoire par le registre de localisation visiteur (VLR). Le MSRN est utilisé pour acheminer les appels MS. Sur demande, le MSRN est envoyé du HLR au commutateur mobile de la passerelle (GMSC).

b) Sous-système de la station de base (BSS) :

Il est principalement responsable de la connexion des appareils mobiles au réseau. Il se compose de deux parties :

- **Station de base de réception (BTS) :**

Les émetteurs-récepteurs radio, ainsi que leurs antennes associées, font partie de la BTS dans un réseau GSM. Ils diffusent et reçoivent des signaux pour se connecter directement aux mobiles. Chaque cellule est définie dans une BTS spécifique. La BTS communique avec les téléphones mobiles via l'interface Um, qui possède son propre ensemble de protocoles.

- **Contrôleur de station de base (BSC) :**

Il gère le sous-système radio, en particulier les BTS. Les principaux rôles du BSC sont la gestion des ressources radio et des transferts. Il est également responsable de la gestion de la puissance. Le BSC contrôle la signalisation et la sécurité du sous-système d'exploitation et de maintenance (OM). Il utilise l'interface Abis pour se connecter aux BTS.[3]

c) Sous-système de changement de réseau (NSS) :

Il gère les changements d'appel entre les utilisateurs de réseau mobile et d'autres réseaux fixes ou mobiles, ainsi que l'administration de services mobiles tels que l'authentification. Le système NSS comprend les éléments fonctionnels suivants :

- **Centre de commutation mobile (MSC) :**

C'est le composant central de l'architecture du réseau GSM. Il fonctionne de manière similaire à un nœud de commutation standard dans un réseau téléphonique public (PSTN) ou un réseau numérique de services intégrés (ISDN), mais il ajoute des capacités pour répondre aux besoins des utilisateurs mobiles. Ces capacités incluent l'authentification des appels, le routage des appels, la localisation des abonnés, le transfert inter-MSC et l'enregistrement.

Le MSC joue également le rôle d'une passerelle vers le PSTN, permettant aux appels de communications mobiles d'être redirigés du PLMN vers un réseau téléphonique public.

- Le MSC se connecte à d'autres MSC, ce qui permet d'établir des appels vers des téléphones mobiles sur divers opérateurs.

➢ **Registre de l'emplacement du domicile (HLR) :**

C'est une base de données qui stocke toutes les informations administratives des abonnés ainsi que leur dernière localisation connue. Lorsqu'un utilisateur accède à son téléphone mobile, il s'enregistre auprès du réseau, ce qui permet d'identifier le BTS (station de base) auquel il est connecté. Les appels entrants sont ensuite dirigés correctement vers l'abonné approprié. Même lorsque le téléphone est éteint ou en mode veille, il enregistre son nouvel état pour garantir que le HLR est à jour concernant son emplacement. Bien qu'il puisse être déployé sur plusieurs sous-centres pour des raisons opérationnelles, chaque réseau ne peut avoir qu'un seul HLR.[2]

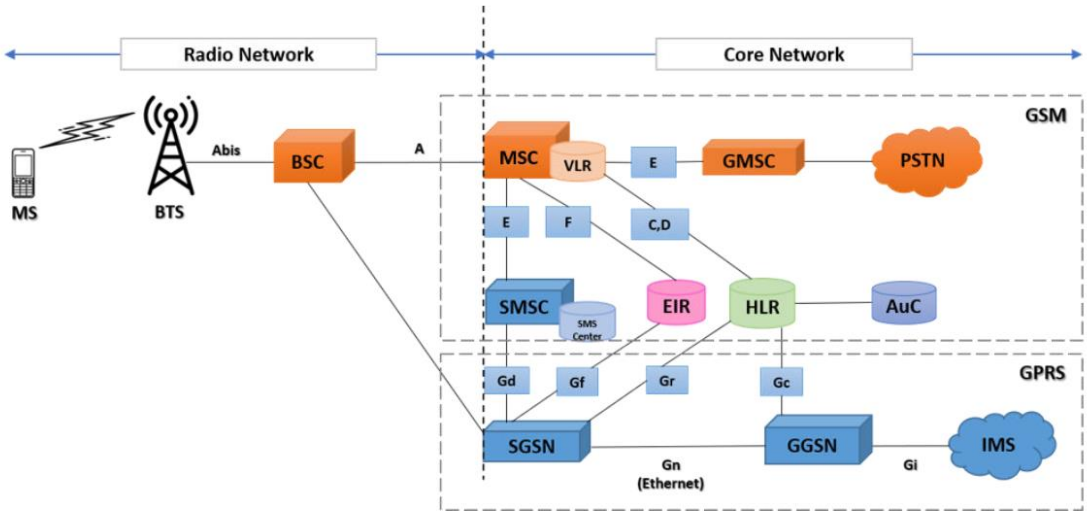


Figure I.2: Architecture globale du GSM et GPRS.

➢ **Registre de l'emplacement des visiteurs (VLR) :**

Il contient des informations provenant du HLR qui autorisent et fournissent des services aux abonnés visiteurs. Bien que le VLR puisse être conçu comme une entité distincte, il est souvent intégré au MSC, ce qui améliore l'accès en le rendant plus rapide et plus efficace.

- **Registre d'identité de l'équipement (EIR) :**

C'est l'autorité qui décide d'autoriser certains appareils mobiles à accéder au réseau. Chaque appareil mobile possède un numéro IMEI (International Mobile Station Equipment Identity). Comme décrit précédemment, ce numéro est installé dans l'appareil et vérifié par le réseau lors de l'enregistrement. En fonction des informations stockées dans l'EIR, le téléphone peut être affecté à l'un des trois états : accès autorisé au réseau, blocage d'accès ou surveillance en cas de problème.

- **Centre d'authentification (AuC) :**

Il s'agit d'une base de données qui stocke la clé secrète, également présente sur la carte SIM de l'utilisateur. Sur la chaîne radio, l'AuC est utilisé pour le chiffrement et l'authentification.

- **Gateway Mobile Switching Center (GMSC) :**

C'est le premier point vers lequel un appel de terminaison mobile est dirigé, même si l'emplacement du téléphone mobile est inconnu. Le GMSC est responsable d'obtenir le MSRN (Mobile Station Roaming Number) du HLR basé sur le MSISDN (Mobile Station ISDN Number) et de diriger l'appel vers le MSC de visite approprié.

d) Sous-système d'exploitation et de support (OSS) :

Il surveille l'ensemble du réseau GSM, régule la charge de trafic du BSS (Base Station Subsystem) et gère les opérations matérielles et de facturation. L'OSS est relié au NSS (Network Switching Subsystem) et au BSS.

I.2.1.2 -Interfaces GSM :

Des interfaces standard ont été créées pour garantir que les réseaux puissent être construits en utilisant des composants de différents fabricants. Cela garantissait qu'ils communiquaient de la même manière, quel que soit le fabricant.

I.2.2 -Transmission radio GSM :

I.2.2.1- Les bandes de fréquences du réseau GSM :

GSM occupent deux bandes à environ 900 MHz, qui sont les suivantes :

- **Up-link: De 890 to 915 MHz.**
- **Down-link: De 935 to 960 MHz**

Chaque bande passante est divisée en 125 canaux (each channel is 200 KHz). Ces canaux ne suffisent pas dans les zones urbaines, il est donc nécessaire d'attribuer une bande supplémentaire (DCS 1800) qui a les mêmes caractéristiques que la bande GSM 900 en termes de protocoles et de services. DCS occupe deux bandes de fréquence autour de 1800 MHz, qui sont:

- **DCS Up-link: De 1710 à 1785 MHz.**
- **DCS Down-link : De 1805 à 1880 MHz**

I.2.2.2 -Techniques d'accès radio dans le GSM :

Les réseaux GSM utilisent des technologies numériques pour transmettre des données par les ondes radio.

Le FDMA (Frequency Division Multiple Access) et le TDMA sont les deux technologies utilisées dans le GSM.

- **La TDMA :** est une méthode de communication qui divise un canal partagé en créneaux temporels distincts, alloués à différents utilisateurs. Cela permet à plusieurs utilisateurs de converser simultanément. La Figure 3a) illustre ce principe.

- **Le FDMA** : quant à lui, est une technique qui sépare différents canaux continus et simultanés à partir d'un seul support de transmission en attribuant des portions distinctes du spectre de fréquences disponibles à chaque canal. Il est employé pour envoyer plusieurs émissions à travers un même transpondeur.

Le terme FDMA se réfère au fait que chaque BTS.

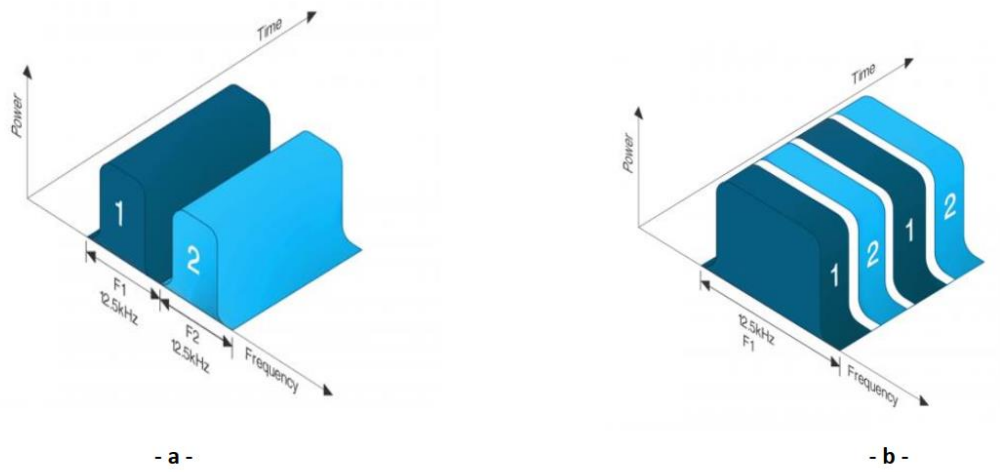


Figure I.3: Diagramme temps/fréquence des techniques d'accès. (b) TDMA, (a)FDMA.

a son propre canal de radiofréquence (RF). La MS dans les cellules voisines (ou la même cellule) peut fonctionner en même temps, bien qu'elles soient séparées par la fréquence. Plusieurs fréquences de transport, 125 dans GSM 900 et 375 dans GSM 1800, sont utilisées dans la technologie FDMA. La figure 3 b) illustre
le principe de FDMA.

I.2.3 -Canaux logiques dans le GSM :

Dans le GSM, des canaux logiques sont utilisés pour transporter le trafic et contrôler les données. Les canaux de trafic sont utilisés pour envoyer des informations aux utilisateurs (speech or data). Les informations de contrôle et de signalisation sont transmises par les canaux de contrôle (CCH) et utilisées pour les services de courts messages. (SMS). Le canal de radiodiffusion cellulaire (CBCH) est utilisé pour envoyer des informations de l'utilisateur d'un centre de service à des stations mobiles dans une zone cellule donnée. Les canaux de contrôle communs (CCCH), de contrôle dédié (DCCH) et de radiodiffusion (BCH) sont les chaînes de contrôle. Les BCH sont utilisés pour la synchronisation des cadres, la correction de la fréquence et la structure du canal de contrôle. Ce sont des chaînes point-à-multi-point qui n'ont qu'un lien vers le bas. Le canal de contrôle de la radiodiffusion (BCCH), le canal de correction de la fréquence (FCCH) et le channel de synchronisation (SCH) sont parmi ces canaux. Le BCCH est utilisé pour envoyer des identités cellulaires, des informations sur les CCCH, le service cellulaire disponible, et ainsi de suite. Les explosions de données de correction de fréquence contenant tous les « 0 » sont transmises sur le canal de correction de fréquences. Cela entraîne un changement constant de fréquence dans le transporteur RF, que la station mobile peut utiliser pour la correction de fréquences.

Le SCH est employé pour maintenir le temps des stations mobiles synchronisé. Le numéro de cadre et le code d'identité BTS (BSIC), qui est requis par les MS lors de la mesure de la force du signal de la station de base, sont parmi les données sur ce canal. Le canal de paginage (PCH), le canal d'accès aléatoire (RACH) et le canal de subvention de l'accès (AGCH) sont des exemples de CCCH. Les stations mobiles sont pagées à l'aide de PCH. À certains moments, les stations mobiles doivent écouter les pages. Les AGCH sont utilisés pour attribuer des téléphones mobiles à des canaux de contrôle dédiés autonomes (SDCCHs). Les RACHs sont des canaux uniquement connectés que les MS utilisent pour transmettre des demandes de connexions réseau dédiées.

Le SDCCH et le canal de contrôle associé (ACCH) sont les deux types de DCCH. Les SDCCH sont des canaux bidirectionnels point-à-point qui sont utilisés pour l'initiation du cryptage, les demandes de service, l'authentification des abonnés, la désignation du canal de trafic (TCH) et la validation de l'équipement. Les ACCH sont des canaux bidirectionnels point-à-poit qui sont reliés à un TCH et SDCCH spécifiques. Les données de signalisation et de contrôle hors bande sont envoyées entre le MS et le BTS par ces canaux. Les mesures de la force du signal d'une MS à la BTS et les informations sur le temps de transmission du BTS à la MS sont deux exemples de leur utilisation. Le tableau 3 résume la plupart des canaux logiques existants et leur rôle dans le réseau GSM. [4]

I.2.4-GPRS :

Pour les systèmes cellulaires 2G, le GPRS a fourni une capacité de données de paquets, permettant à GSM d'évoluer pour inclure une possibilité de données.

Des entités de réseau supplémentaires doivent être ajoutées à l'architecture globale à cette fin; trois des plus importantes.

Tableau I.1: La plupart des canaux logiques dans le système GSM.

CANAL LOGIQUE	ROLE DU CANAL LOGIQUE
TCH/F	Chaîne de trafic à taux complet pour transporter une charge utile à 22,8 kbps.
TCH/H	Canal de trafic à moitié rapide pour transporter une charge utile à 11,4 kbps.
BCCH	Diffusion d'informations sur le réseau.
SCH	Synchronisation des stations mobiles.
FCCH	Utilisé pour la correction de la fréquence.
AGCH	Accepte une demande de canal à partir d'un appareil mobile et lui attribue un SDCCH
FACCH	La panne de circulation est volée pour une panne complète de signalisation TCH, par exemple pour la surveillance des liens, pour la signalisation critique du temps sur TCH (par exemple, pour le signal de déchargement.
SACCH	Signalisation TCH en bande, par exemple, pour la surveillance des liens.
SDCCH	Mise à jour de l'enregistrement/de l'emplacement FACCH pour SDCCH pendant l'échange de signaux, par exemple lors de la configuration d'appel. Pour une explosion de signalement complète, l'explosion SDCCH est volée.
FACCHS	Pour SDCCH, FACCH est l'acronyme. Pour une éruption complète de signal, l'éruption SDCCH est volée.
SACCHS	Signalisation SDCCH en bande, par exemple, pour la surveillance des liens.

sont le nœud de service de la passerelle GPRS (GGSN) et le noyau d'appui de la prise en charge de la transmission (SGSN), ainsi que l'unité de contrôle des paquets (PCU) comme indiqué dans la figure 2.

GPRS pour fournir une connectivité supplémentaire en termes de données de paquets.

- **SGSN :** Offre une gamme de services axés sur les parties IP du système global. Il propose divers services mobiles tels que le routage et le transfert de paquets, la gestion de la mobilité, l'authentification et la gestion des données de charge.

- **GGSN :** Constitue une composante essentielle de l'architecture du réseau GPRS. Il peut être décrit comme une fusion entre une passerelle, un routeur et un pare-feu. Lorsque le GGSN reçoit des données destinées à un utilisateur spécifique, il vérifie préalablement la présence en ligne de cet utilisateur avant de transférer les données.
- **PCU :** Connecté au BSC, le PCU est un routeur matériel qui assure la conversion des données entre le réseau GSM standard (données de circuit commutées) et les réseaux GPRS (données de GPRS), et vice versa.

I.2.5-L'EDGE :

L'introduction de la technologie EDGE a contribué à atténuer certaines des limitations du réseau GPRS. Compatible à la fois avec les réseaux TDMA et GSM, EDGE peut être intégré à toute infrastructure prenant en charge le GPRS, en étant considéré comme un sous-ensemble de cette dernière. Avec un débit théorique atteignant 500 kbps, EDGE utilise la modulation de phase-shift keying (PSK) pour parvenir à cette performance. Les améliorations apportées par EDGE comprennent une augmentation du débit par tranche horaire (de 8,8 à 59,2 kbps / tranche horaire), le passage de la modulation GMSK à 8-PSK, une réduction de la sensibilité du signal, ainsi qu'une augmentation de la capacité et de la couverture.

En dehors de quelques modifications matérielles mineures au niveau des stations de base (BTS) et des mises à niveau logicielles du réseau, l'implémentation d'EDGE ne requiert pas de modifications matérielles majeures. [2]

I.2.6 -Paramètres d'optimisation du réseau en 2G :

I.2.6.1 -Indicateurs clés de rendement dans le GSM :

Les indicateurs clés de performance (KPI) servent à évaluer avec succès la performance et la qualité d'un réseau. Ils sont utilisés pour plusieurs objectifs :

- Surveiller et améliorer les performances du réseau de communication afin d'offrir un service de meilleure qualité aux abonnés.

- Détecter rapidement les problèmes liés à des performances inacceptables dans un réseau cellulaire.

- Fournir des informations détaillées aux planificateurs RF.

- **Accessibilité :** mesure la capacité à établir une communication.
- **Retenabilité :** mesure la capacité à maintenir la connexion existante.
- **Mobilité :** mesure la capacité à maintenir la connexion de l'utilisateur lors de déplacements sur le réseau.
- **Intégrité :** mesure le niveau de service après que l'utilisateur a accédé au service.

I.2.6.2 -Principaux KPIs dans le GSM :

Inclure tous les paramètres suivants:

- **Taux de réussite de mise en place d'appels (CCSR) :** Ce KPI mesure le nombre de tentatives d'appels réussies par rapport au nombre total de tentatives d'appels. Un appel est considéré comme réussi s'il parvient à établir une connexion SDCCH, puis à accéder avec succès à un canal TCH.

  Le CCSR est principalement impacté par le blocage des canaux (SDCCH/TCH) ou par

des problèmes opérationnels.

- **Taux d'appel arrêté (DCR) :** Ce KPI compare le nombre d'appels interrompus au nombre total d'appels configurés avec succès. Lorsqu'un canal TCH est rejeté pendant une réaffectation, un appel est considéré comme interrompu. Du point de vue RF, le DCR dépend du délai de connexion radio (RLT) et de la qualité de la transmission. Le RLT est influencé par des facteurs tels que les interférences et la couverture insuffisante. Le DCR peut également être affecté par des problèmes opérationnels.
- **Taux de réussite des transferts (HSR) :** Ce KPI compare le nombre de transferts réussis au nombre total de tentatives de transfert. Il existe deux types de HSR : sortant (ex-HSR) et entrant (en-HSR). Le HSR sortant dépend des paramètres de contrôle d'adjacence et de la qualité de la transmission. Le HSR entrant dépend également des paramètres d'adjacence et est affecté par le blocage de canaux TCH sur la cellule source.
- **Minutes par goutte (MPD) :** Ce KPI représente le nombre moyen de minutes avant qu'un appel ne soit abandonné du réseau. Par exemple, un MPD de 60 minutes signifie qu'un appel reste en moyenne sur une cellule pendant 60 minutes avant d'être abandonné. Le MPD est calculé en divisant le trafic vocal total par le nombre total de gouttes TCH.
- **Blocage brut TCH :** Ce KPI mesure le blocage des canaux TCH pendant la configuration des appels. Il n'inclut pas le blocage des canaux TCH dû aux tentatives de transfert entrant ou au blocage des canaux TCH lors de tentatives d'arrestation de la TCH entrante dans le cadre d'une réaffectation ciblée.
- **Blocage du SDCCH :** Ce KPI mesure les tentatives d'accès au SDCCH qui n'ont pas pu être réalisées en raison de son indisponibilité.

I.3- Le système de réseau mobile de troisième génération :

La deuxième génération de technologie mobile, entièrement numérique, a introduit des fonctionnalités telles que les SMS et le GPRS. La troisième génération (3G) a été développée pour gérer des débits de données plus élevés et offrir des services comme la télévision mobile et les appels vidéo. L'UMTS, une évolution majeure de la 3G, a été significativement amélioré pour fournir des vitesses de bande passante bien au-delà de sa conception initiale, grâce à des améliorations appelées accès à des paquets à haute vitesse (HSPA). L'architecture réseau a été entièrement repensée dans le cadre de la norme UMTS, mettant en œuvre une nouvelle technologie appelée WCDMA (Accès multiple par répartition en code à large bande) plutôt que de s'appuyer sur les capacités de multiplexage temporel et fréquentiel de l'interface Um. L'introduction la huitième version des spécifications du 3GPP a permis de capitaliser sur les avancées de HSPA et HSPA+. Cette technologie permet aux consommateurs d'accomplir des tâches sur des appareils aussi efficacement que s'ils étaient connectés à un réseau large bande à domicile ou au bureau. Cette section explore l'architecture des réseaux UMTS, y compris ses sous-systèmes et leurs fonctions, ainsi que les différents processus réseau tels que les transferts, et met en lumière le concept de WCDMA utilisé pour le développement des réseaux. Elle aborde également les améliorations et changements architecturaux, ainsi que le processus d'optimisation du réseau qui a fait progresser l'UMTS.

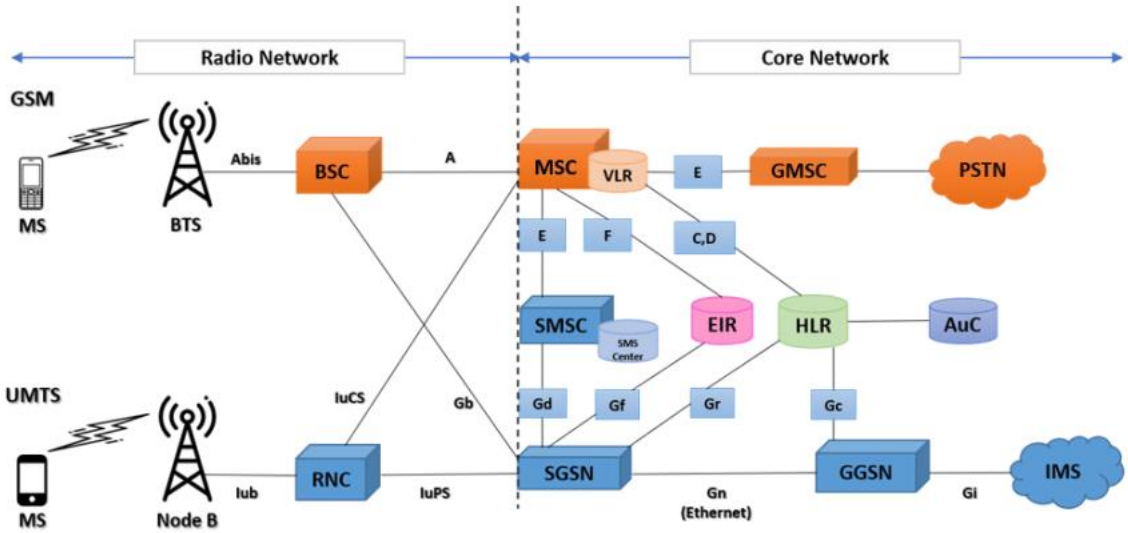


Figure I.4: Architecture de réseau UMTS connectée à un réseau hérité.

I.3.1- Réseau UMTS :

La norme de transmission radio pour l'UMTS repose sur le code de bande large WCDMA. De nombreux concepts utilisés dans le GSM ont été transférés et améliorés pour l'UMTS. Par exemple, la carte SIM a été évoluée en une carte SIM universelle (USIM). De plus, le réseau a été conçu de manière à pouvoir bénéficier des avancées GPRS et EDGE, minimisant ainsi les investissements nécessaires.

La topologie du réseau de base (CN), inspirée par le GSM, se compose de deux domaines principaux pour le trafic utilisateur : les domaines commutés par paquets (PS) et commutés par circuit (CS). Ces deux domaines gèrent simultanément leurs types de trafic respectifs pour les réseaux GSM et UMTS. Le domaine CS, composé des entités MSC et GMSC, gère tout le trafic commuté pour les réseaux GSM et UMTS, tandis que le domaine PS, comprenant le réseau d'accès GPRS, est responsable de tout le trafic commuté par paquets pour les entités SGSSN et GGSN.[5]

En ce qui concerne l'administration des abonnés, l'itinérance, l'identification des stations mobiles et la gestion des divers services, les domaines PS et CS utilisent des caractéristiques communes des entités de réseau telles que le HLR en conjonction avec l'EIR et le AuC. Ainsi, le HLR contient des informations sur les abonnés pour les réseaux GSM, GPRS et UMTS.

I.3.1.1 Architecture UMTS :

Avec le GPRS, l'inclusion des données de paquets a nécessité la création de plus d'entités réseau. La conception de réseau UMTS a été construite sur la fusion de ces deux pièces de réseau. La figure I.4 montre l'architecture UMTS totale avec le réseau GPRS. Il y a trois parties de base à la conception de réseau UMTS :

I.3.1.2 Le réseau d'accès radio :

L'équipement utilisateur (UE) représente un élément essentiel de l'architecture globale du réseau 3G. Il agit comme l'interface finale de l'utilisateur et se compose de plusieurs composants :

- **Circuit RF :** Ce composant gère tous les aspects du signal, à la fois en réception et en transmission. L'optimisation de la consommation d'énergie est un défi majeur pour l'amplificateur de puissance RF, surtout avec l'introduction de la modulation WCDMA qui nécessite l'utilisation d'un amplificateur linéaire.

- **Traitement de la bande de base :** Il s'agit d'un circuit numérique crucial qui effectue la majeure partie du traitement du signal en bande de base.
- **Batterie :** La considération de la batterie est primordiale lors de la conception du circuit pour garantir une consommation réduite. Les batteries lithium-ion (Li-ion) sont désormais largement utilisées pour maintenir une taille compacte et légère tout en offrant une durée de vie de charge globale satisfaisante.
- **USIM :** Il s'agit d'une version évoluée de la carte SIM utilisée dans le GSM. Bien qu'elle contienne des informations utilisateur similaires telles que le MSISDN et l'IMSI, elle présente des fonctionnalités et des capacités améliorées.
- **L'UTRAN :** également désigné sous le nom de sous-système de réseau radio (RNS), est constitué de deux éléments principaux :
- **Node-B :** Il s'agit de la station de base du réseau UMTS, chargée du traitement des signaux dans l'interface Uu. Ses fonctions principales incluent l'interfaçage, l'adaptation du débit, la diffusion, le codage des canaux, la gestion des ressources radio (RRM) et le contrôle de puissance.[5]
- **Contrôleur de réseau radio (RNC) :** Cet élément assure la gestion des ressources radio et des Node-B qui y sont connectés. Il est responsable de l'admission des appels, de la RRM, de l'allocation de codes, du contrôle de puissance, de la planification de paquets, de la gestion des transferts et du cryptage du domaine CS.

I.3.1.3- Les techniques d'accès radio :

WCDMA qui est une variante de duplexage par répartition dans le temps (TDD) et de duplexage par répartition en fréquence (FDD), constitue la forme de spectre étalé sous-jacente à WCDMA, qui est la principale technologie d'accès radio utilisée dans UMTS. Les concepts de base utilisés dans le système WCDMA sont les suivants : le canalisage, le brouillage, le codage de canal, le contrôle de puissance et le transfert intercellulaire.[5]

I.3.1.4- Contrôle de puissance :

Le contrôle de puissance est essentiel pour la technique WCDMA et utilisé principalement pour :

- Calculer la puissance minimale requise pour la transmission, afin d'obtenir une performance adéquate de la liaison radio.
- Maintenir un rapport signal sur interférence (SIR) élevé tout au long de la conversation. Trois niveaux.

de contrôle de puissance sont mis en œuvre, à savoir :

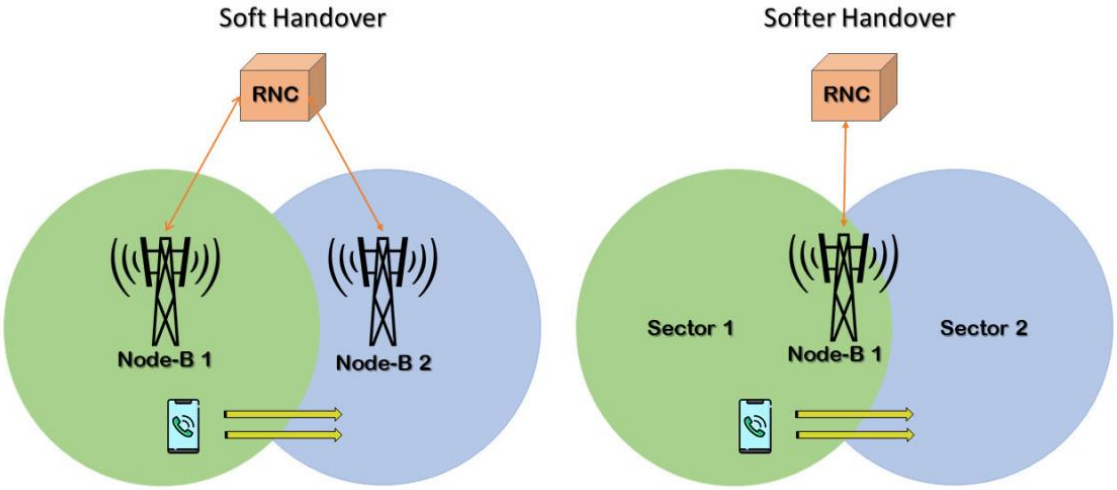


Figure I.5: Types de transfert dans le réseau UMTS.

- **Boucle ouverte :** Les communications descendantes et montantes utilisent le mécanisme de contrôle de puissance en boucle ouverte. Il fournit un réglage initial de la puissance de l'UE pour le canal montant. Le niveau de signal calculé par l'UE dans le canal descendant ne peut pas être utilisé par le système WCDMA FDD.[5]
- **Boucle fermée :** Le contrôle de puissance utilisant une boucle fermée maintient le niveau de signal reçu de chaque seuil de signal montant du mobile, réduisant ainsi les interférences dans la cellule.

I.3.1.5- Sélection de cellules :

Les cellules du réseau UMTS peuvent être classées en trois états différents :

- **Ensemble actif :** Toutes les cellules de l'ensemble actif reçoivent des informations sur l'utilisateur. Les cellules actives dans FDD sont impliquées dans le transfert doux. L'ensemble actif dans TDD se compose toujours d'une cellule. Seules les cellules actives dans la liste d'informations de cellules dynamiquement variables seront considérées par l'UE.
- **Ensemble surveillé :** Les cellules qui ne font pas partie de l'ensemble actif mais qui font partie de la liste d'informations cellulaire.

- **Ensemble détecté:** Inclut toutes les cellules détecter par l'UE qui ne sont ni par les EU

sont admissibles à la déclaration des mesures de l'ensemble détecté.

Il existe trois scénarios dans lesquels l'état d'une cellule donnée peut changer :

– Lorsque le signal d'une cellule est assez fort pour l'activer.

– Lorsqu'une cellule de l'ensemble actif devient faible et doit être supprimée.

– Lorsque le signal d'une cellule non active s'améliore au point où il est supérieur à celui d' une cellule active, la nouvelle cellule plus forte remplace celle plus faible dans l'ensemble actif. dans la liste d'informations cellulaires ni dans l'ensemble actif. Seules les mesures intra-fréquentes effectuées.

I.3.2- Principaux paramètres et répartitions du spectre dans le réseau UMTS :

La majeure partie du spectre WCDMA est d'environ 2 GHz, avec des fréquences de connexion allant de 1920-1980 MHz et des fréquences de liaison allant du 2110-2170 MHz. Ce spectre est un élément clé de la norme IMT-2000, qui est utilisée en Europe, en Asie et au Brésil. Le réélevage se réfère au processus de déploiement du WCDMA dans une bande de fréquences GSM ou CDMA existante. Les principaux paramètres de la technologie WCDMA.

I.3.3- Canaux UMTS :

En fonction des spécificités du service offert, tout service fourni à UE est associé à un support radio qui définit la configuration et le réglage du contrôle de liaison radio (RLC), du contrôle d'accès moyen (MAC) et de la couche physique. À différents niveaux de protocole, le flux d'information associé à un signal d'accès radio (RAB) est cartographié dans différents types de canaux. La couche RLC crée des canaux logiques, qui sont ensuite cartographiés pour transporter des canais dans la couche MAC. Deux types de canaux logiques fournissent les porteurs de plan de commande et de plan d'utilisateur : les canaaux de contrôle pour la signalisation et les canais de circulation pour le porteur. Les canaux logiques existants sont résumés dans le tableau 2.

I.3.4- États du RRC :

La machine d'état RRC dispose de deux modes: mode RRC en mode inactivité et mode connecté RRC.

Tableau I.2: La plupart des canaux logiques existants dans le système UMTS

CANAUX	L'UTILISATION	DEPRECIATION
	CANAUX DE CONTROLE	
Canal de contrôle de radiodiffusion (BCCH)	Transmission du message du système d'information contenant des séquences de code, un identifiant de cellule, des chronomètres,...etc.	DL
Canal de contrôle des pages (PCCH)	Les appels entrants ou d'autres messages doivent être annoncés aux utilisateurs dans la zone de localisation	DL
Canal de contrôle dédié (DCCH)	Chaque utilisateur ayant une connexion RRC à la RNC a un canal de signalisation bidirectionnel. Il envoie des rapports de mesure ainsi que des messages de contrôle RRC	DL ou UL
Canaux de contrôle communs (CCCH)	Configuration de la connexion, affectation du canal et réélection des cellules	DL ou UL
	CANAUX DE TRAFIC	
Chaîne de trafic dédiée (DTCH)	Les informations pour le service spécifique d'un seul utilisateur sont transférées. Plusieurs services peuvent être fournis à un seul utilisateur sur plusieurs DTCHs coexistants en même temps	DL et UL
Canaux de trafic communs (CTCH)	Le message de diffusion cellulaire SMS, par exemple, est un canal point à multipoint qui transporte des informations pour un groupe d'utilisateurs	DL
	CANAUX DE TRANSPORT	
Chaîne de diffusion (BCH)	Le transport du canal logique BCCH est assuré par ce composant	DL
Canaux de pagination (PCH)	Le transport du canal logique PCCH est assuré par ce composant	DL
Canal d'accès aléatoire (RACH)	Avant qu'un canal de trafic puisse être attribué, des informations de signalement courtes doivent être fournies lors de l'accès initial au système	UL
Envoyer le canal d'accès (FACH)	Un canal logique est porté pour une UE spécifique. Réponse de RACH	DL

Canaux de paquets communs (CPCH)	Le canal RACH a été élargi pour permettre la transmission de plus grands paquets de données	UL
Télécharger le canal partagé (DSCH)	Similaire au GPRS, un pool de ressources physiques est alloué sur une base d'intervalle de transmission temporelle (TTI) à différents utilisateurs en fonction de la politique de planification des paquets	UL

I.3.4.1- Mode de connexion RRC :

L'Union européenne (UE) a la capacité de transmettre des données en utilisant des ressources radio allouées en mode RRC connecté. Chaque équipement utilisateur (UE) dispose ainsi d'une identité de réseau radio temporaire (RNTI) qui le distingue dans des canaux partagés comme le RACH ou le CPCH. La figure 8 illustre la séquence de messages nécessaire à l'établissement d'une connexion RRC. Le canal de commande montant commun (uplink CCCH) est associé au RACH, permettant à l'UE d'envoyer un message de demande de connexion RRC. L'UTRAN, tout comme toute autre demande du réseau d'accès radio, doit mettre en place un porteur radio de signalisation (SRB) entre l'UTRAN et l'UE. Chaque appareil mobile est identifié par son ID UE initial, qui correspond à un identifiant NAS similaire à l'IMSI ou au TMSI. Le contenu de la demande de connexion RRC inclut l'identifiant UE initial, tel que mentionné par.[5]

I.3.5- Optimisation du réseau UMTS :

I.3.5.1- KPIs en UMTS :

Les KPIs du réseau UMTS peuvent être divisés dans les sous-catégories suivantes :

- **Accessibilité** : c’est la capacité de l’utilisateur de se connecter avec succès au réseau UMTS et d’utiliser

les services disponibles.

- **Retenabilité :** Il est défini comme la capacité d’un utilisateur à conserver un service demandé pendant

le temps spécifié.

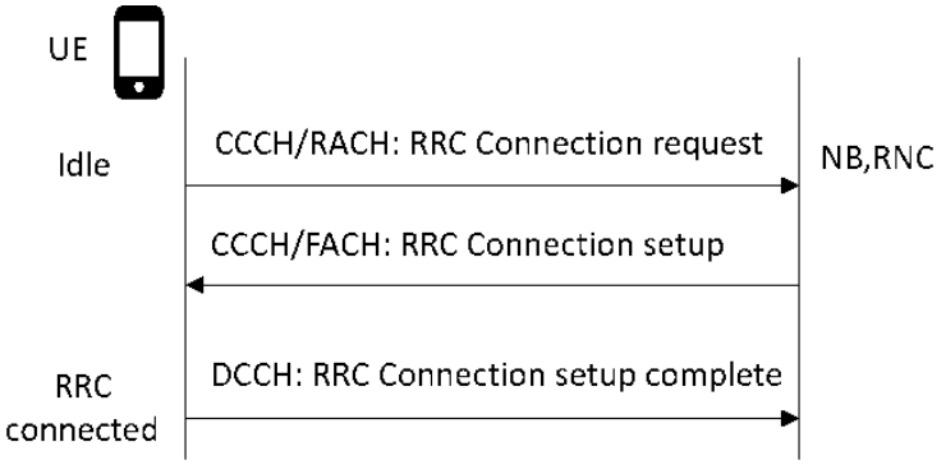


Figure I.6: RRC connection establishment.

Tableau I.3: Optimisation de l'appel-décharge CS.

POSSIBLE REASONS	RESOLUTIONS
MAUVAISE COUVERTURE	Ajustez l'inclinaison et l'azimuth de l'antenne.
QUESTIONS RELATIVES A LA PLANIFICATION DU VOISINAGE	Vérifiez si les voisins planifient les cellules dans la région
ÉMISSION DE PUISSANCE A LARGE BANDE TOTALE (RTWP) REÇUE	Traçage de la source de l'interférence externe à l'aide d'un spectre analyseur ou vérifier le matériel connexe
ALARMES	Rectification UTRAN
PROBLEME D'EXCEDENT	Les conditions RF doivent être vérifiées
CONFLIT DE PLANIFICATION DU CODE (SCP) (CELLS COVERAGE)	Replanter les cellules souches pluripotentes (PSC)

- **Mobilité :** Cette caractéristique concerne la capacité d'un utilisateur à se déplacer entre les cellules UMTS et GSM voisines tout en maintenant le service requis, qu'il s'agisse de services de paquets (PS) ou de services de circuit (CS).
- **Integrity:** represent the user's perception of quality.

Les principaux KPIs du réseau UMTS sont la baisse des appels CS ou PS, l'échec de la configuration de la connexion RRC, la défaillance de la HO (3G-3G), l'échec de l'IRAT-HO (3G-2G) et le problème de la congestion d'alimentation.

I.3.5.2- Optimisation des KPIs :

Tous les KPIs mentionnés ci-dessus aident à l'optimisation continue du réseau, qui est une partie essentielle de ses opérations. En les surveillant, plusieurs problèmes au sein du réseau peuvent être identifiés et résolus au besoin, comme indiqué dans les tableaux 3, 4, 5, 6, 7 et 8.

Tableau I.4: Optimisation des appels PS.

RAISONS POSSIBLES	RESOLUTIONS
MAUVAISES CONDITIONS RF	Ajustements d'antenne
PROBLEME DE VOISIN MANQUANT	Vérifiez si les voisins planifient les cellules dans la région
PROBLEME RTWP	Suivi de la source de l'interférence externe à l'aide d'un analyseur de spectre ou du matériel qui doit être vérifié
ALARMES	Rectification UTRAN
SUIVI DE L'UE SPECIFIQUE	Vérifier les journaux de l'historique des appels (CHR)

Tableau I.5: Optimisation de la défaillance de la connexion RRC.

CAUSES POSSIBLES	RESOLUTIONS
Échec du RRC	Appliquer une analyse de rejet RRC
Congestion électrique	Augmenter la puissance de sortie ou vérifier les problèmes de RTWP
Congestion CE	Équilibrage des charges Congestion de code Vérifier les codes HSDPA
Pas de réponse	Question de l'UE
Question de l'UE	Analyse de scénario cellulaire

Tableau I.6: Optimisation de la défaillance de HO.

CAUSES POSSIBLES	RESOLUTIONS
Problème d'excédent	Vérifier les conditions RF
Problème de voisin manquant	Vérifier la planification des cellules dans la zone
Vérifier la planification des cellules dans la zone	seuil d'événement de transfert seuil d'événement de transfert de Retune
Collision PSC	Replanter les cellules PSC
Mauvaise couverture	Ajustements d'antenne

I.4- Le système de réseau mobile de quatrième génération :

I.4.1- Vue d'ensemble du réseau LTE :

L'objectif principal de LTE est d'offrir des débits de données supérieurs à ceux de l'UMTS, tout en proposant une technologie d'accès radio à faible latence et optimisée pour les paquets, ce qui permet une utilisation flexible de la bande passante. Son architecture réseau est conçue pour prendre en charge le trafic de commutation de paquets tout en maintenant une qualité de service et une mobilité élevées. Par rapport aux systèmes cellulaires précédents, LTE a introduit de nombreuses nouvelles technologies qui lui permettent de fonctionner de manière plus efficace en termes d'utilisation du spectre tout en offrant les débits de données plus élevés nécessaires.qui sont requis:

- **OFDM :** Ce format de signal, utilisé dans LTE, permet la transmission efficace de larges bandes passantes de données tout en résistant aux interférences et aux réflexions. En répartissant le trafic sur plusieurs transporteurs, le système peut maintenir sa performance même en cas de perte de certains d'entre eux en raison d'interférences ou de réflexions. Le système utilise des méthodes d'accès différentes pour le uplink et le downlink.
- **Accès multiple à division de fréquence orthogonale (OFDMA) :** Cette méthode offre une robustesse face à l'affaiblissement et à l'interférence de multiples voies. Elle est utilisée dans le downlink. Pour le uplink, le système utilise un seul porteur d'accès multiple à division de fréquence (SC-FDMA) car il présente un pic de rapport signal sur bruit moyen plus faible que l'OFDMA, ce qui prolonge la durée de vie de la batterie des appareils.
- **Multiple entrées, multiples sorties (MIMO) :** Cette technologie exploite les signaux multipath pour augmenter le débit. Elle nécessite plusieurs antennes pour distinguer les différentes voies de communication.
- **Évolution de l'architecture du système (SAE) :** Alors que LTE fait référence à l'évolution de l'accès radio UMTS via E-UTRAN, SAE concerne l'évolution des aspects non radio, notamment le réseau de cœur de paquets évolué (EPC). Le système évolué de paquets (EPS) comprend LTE et SAE. Pour acheminer le trafic IP entre une passerelle et l'UE, EPS utilise le concept de "porteurs EPS", qui sont des flux de paquets IP avec une qualité de service définie. E-UTRAN et EPC établissent et libèrent des porteurs selon les besoins des applications.

- **Données IP :** LTE est entièrement basé sur IP, excluant la voix en circuit qui était présente dans l'UMTS. Initialement, les opérateurs prévoyaient de fournir des données tandis que la voix serait gérée par des applications over-the-top (OTT). Pour remédier à cela, la GSM-Association (GSMA) a établi VoLTE comme norme de l'industrie. Le déploiement de cette fonctionnalité a été retardé en raison du coût de construction d'un sous-système multimédia IP (IMS).

Tableau I.7: Optimisation des défaillances de l'IRAT HO.

CAUSES POSSIBLES	RESOLUTIONS
Différences de cellules GSM	Supprimer toutes les divergences de cellules GSM
Interférence sur la cellule GSM	Suivre et résoudre les interférences
Paramètres IRAT	Rétablir les paramètres de l'IRAT
Émission de cellule particulière	Filtrer les cellules avec des défaillances IRAT continues

Tableau I.8: Optimisation de la congestion électrique.

CAUSES POSSIBLES	RESOLUTIONS
Problème RTWP	Vérifier le matériel
Problème de sortie d'alimentation	Augmenter la puissance TCP et CPICH pour accroître la couverture et la capacité
Surcharge de la cellule	Vérifier les conditions RF

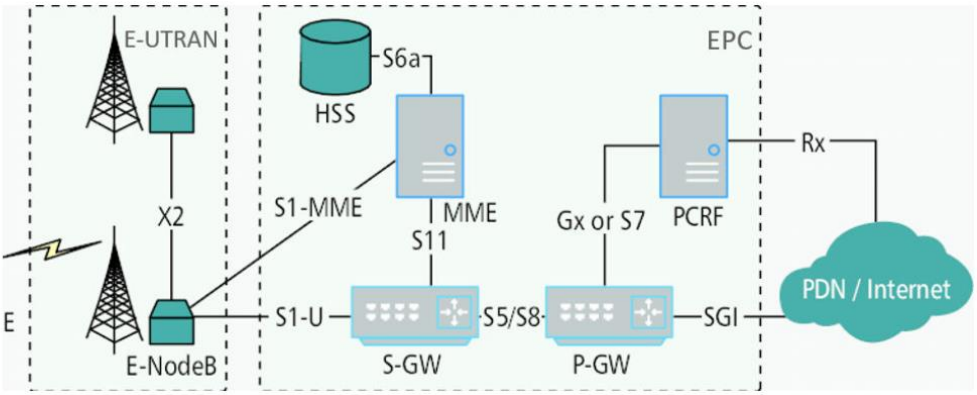


Figure I.7: Architecture de réseau LTE.

I.4.2- Architecture de réseau LTE :

LTE a été créé pour supporter uniquement les services PS, avec l'objectif de fournir une

connectivité IP sans soucis entre l'UE et le PDN sans causer d'interruption aux services des utilisateurs finaux lorsqu'ils se déplacent. Le niveau supérieur du réseau LTE est composé des trois entités principales suivantes (figure 7) : l'EPC, l'UE et l'E-UTRAN.

I.4.3- Réseau d'accès radio dans LTE :

I.4.3.1-L'Union européenne :

L'architecture interne des équipements utilisateurs LTE est similaire à celle de l'UMTS. Les modules importants suivants ont été inclus dans l'UE :

- **Termination mobile (MT) :** C'est le composant chargé de gérer tous les aspects de la communication.
- **Équipement terminal (TE) :** Il assure la déconnexion du flux de communication.
- **Carte de circuit intégré universelle (UICC) :** Dans le contexte des équipements LTE, cette carte est appelée USIM. Elle ressemble à une carte SIM 3G et stocke des données spécifiques à l'utilisateur telles que son numéro de téléphone, les clés d'identité et de sécurité du réseau domestique, etc.

I.4.3.2- L'E-UTRAN:

Les eNodeB ou eNB sont les éléments centraux de l'E-UTRAN, responsables de la gestion des communications radio entre les équipements utilisateur (UE) et le cœur de réseau EPC. Chaque eNB agit comme une station de base pour une ou plusieurs cellules, contrôlant les appareils mobiles dans sa zone de couverture. La station de base avec laquelle le mobile communique est appelée le service eNB. Dans LTE, un mobile se connecte à une seule station de base et à une seule cellule à la fois. Les eNB remplissent deux rôles principaux :

- En utilisant le signal numérique de l'interface radio LTE et en tirant parti des fonctionnalités de traitement analogique, l'eNB transmet et reçoit des transmissions radio à destination de tous les appareils mobiles.
- L'eNB est responsable de toutes les opérations de base des téléphones mobiles, en leur envoyant des messages de signalisation comme des commandes de transfert.

L'interface S1 connecte chaque EPC à l' eNB, et la interface X2 la relie aux stations de base à proximité, qui est principalement utilisée pour la signalisation et le transfert de paquets lors du transfert.

I.4.3.3- Réseau de base LTE:

Il est constitué d'éléments qui effectuent diverses tâches telles que l'authentification de la mobilité, la gestion des ressources, le contrôle de la qualité de service, le traitement des données

d'itinérance des paquets IP, l'attribution des adresses IP, etc. L'architecture IP plane de l'EPC permet au réseau de gérer de manière efficace et économique des volumes importants de trafic de données. Il se compose de :

- **Entité de gestion de la mobilité (MME) :**est une composante cruciale du réseau mobile, assurant plusieurs fonctions vitales :

  -Authentification : Le MME facilite l'authentification des utilisateurs sur le réseau après l'échange d'informations d'authentification entre le HSS et les UEs. Cela garantit que seuls les utilisateurs autorisés peuvent accéder au réseau.

  -Gestion de la mobilité : Le MME permet aux abonnés de se déplacer librement sur le réseau ou entre les réseaux, assurant une connectivité fluide même lors des transitions entre différentes stations de base.

  -Mise à jour de l'emplacement : Le MME maintient une trace de la position et de l'état des abonnés sur le réseau, ce qui est essentiel pour acheminer efficacement les appels, les messages et les données vers les utilisateurs où qu'ils soient.

  -Établissement des porteurs : Lorsque plusieurs passerelles sont disponibles, le MME détermine les itinéraires vers l'Internet en établissant des porteurs sur une passerelle appropriée, garantissant ainsi une connectivité optimale pour les données des utilisateurs.

  -Support de handover : Le MME active le transfert inter-eNodeB (pour le transfert de connexion lors d'un handover sur l'interface S1), assurant une continuité de service transparente lors du déplacement d'un utilisateur entre différentes stations de base.

  -Lorsque l'interface X2 n'est pas disponible, l'MME envoie des messages d'affectation entre les eNodeBs, exploitant ainsi les capacités de transfert de ces derniers.

Le MME assume plusieurs responsabilités cruciales dans le réseau LTE. Il génère et alloue des identités temporaires aux UEs et gère la cessation de la signalisation NAS. Il vérifie l'autorisation des UEs à se connecter au PLMN du fournisseur de services et applique les restrictions d'itinérance.

De plus, le MME joue un rôle essentiel dans le cryptage, la protection de l'intégrité et la gestion des clés de sécurité pour la signalisation NAS. Il facilite également l'interception légale des signaux. L'interface S3 se termine au MME du SGSN, fournissant ainsi la fonction de plan de contrôle pour la mobilité entre les réseaux d'accès 2G/3G et les nœuds d'accès LTE. En cas d'itinérance des UEs, le MME établit également une interface S6a avec le HSS d'accueil.

- **Serveur d'abonnés à domicile (HSS) :** Le HSS enregistre les détails de l'abonnement SAE de l'utilisateur, y compris le profil QoS souscrit à EPS et les restrictions d'accès en

itinérance. Il stocke également des informations sur les PDN accessibles par l'utilisateur, utilisant des noms de points d'accès (APN) ou des adresses PDN. De plus, le HSS conserve des données dynamiques telles que l'identité du MME auquel l'utilisateur est actuellement connecté ou enregistré. Il peut également héberger le AuC, qui génère des vecteurs de clés d'authentification et de sécurité.

- **Porte de service (SGW) :** Le SGW agit comme une ancre de mobilité locale pour les porteurs de données lorsque l'UE se déplace entre les eNodeB. Il transfère tous les paquets IP utilisateur et enregistre des informations sur les porteurs lors de l'inactivité de l'UE, sauvegardant temporairement les données des liens vers le bas. Le SGW collecte également des données à des fins d'interception et de recouvrement judiciaires. Il sert également d'ancre de mobilité pour d'autres technologies telles que l'UMTS et le GPRS, facilitant leur communication entre eux.
- **Port de réseau de données de paquets (P-GW) :** Le P-GW attribue des adresses IP aux UEs, gère la charge et applique le QoS conformément aux règles du PCRF. Il filtre les paquets IP de l'utilisateur en aval et les distribue aux différents porteurs basés sur le QoS, utilisant des modèles de flux de trafic (TFTs). Pour les porteurs de taux de bits garanti (GBR), le P-GW applique également le QoS.

  Il agit également comme une ancre de mobilité pour les technologies non 3GPP telles que les réseaux CDMA2000 et WiMAX, facilitant leur communication entre eux.
- **Fonction des règles de politique et de charge (PCRF) :** Le PCRF, hébergé dans le P-GW, prend des décisions de contrôle des politiques et des fonctionnalités de charge basées sur le flux. Il fournit l'autorisation QoS, déterminant le traitement du trafic dans le PCEF et garantissant sa conformité au profil d'abonnement de l'utilisateur.

I.4.4 Interfaces LTE :

- **LTE-Uu :** Assurant la liaison entre les équipements utilisateur (UE) et les stations de base (eNodeBs), le LTE-Uu est chargé de gérer tous les échanges de signalisation entre le MME et le eNodeB, ainsi que du transfert de données entre le S-GW et l'UE.
- **S1 :** L'interface S1 relie l'E-UTRAN et l'EPC pour les besoins de contrôle et d'utilisateur. Elle se compose de deux parties distinctes : la S1-AP (GTP-AP) pour le contrôle, et la S1U (GTP-U) pour les données utilisateur.

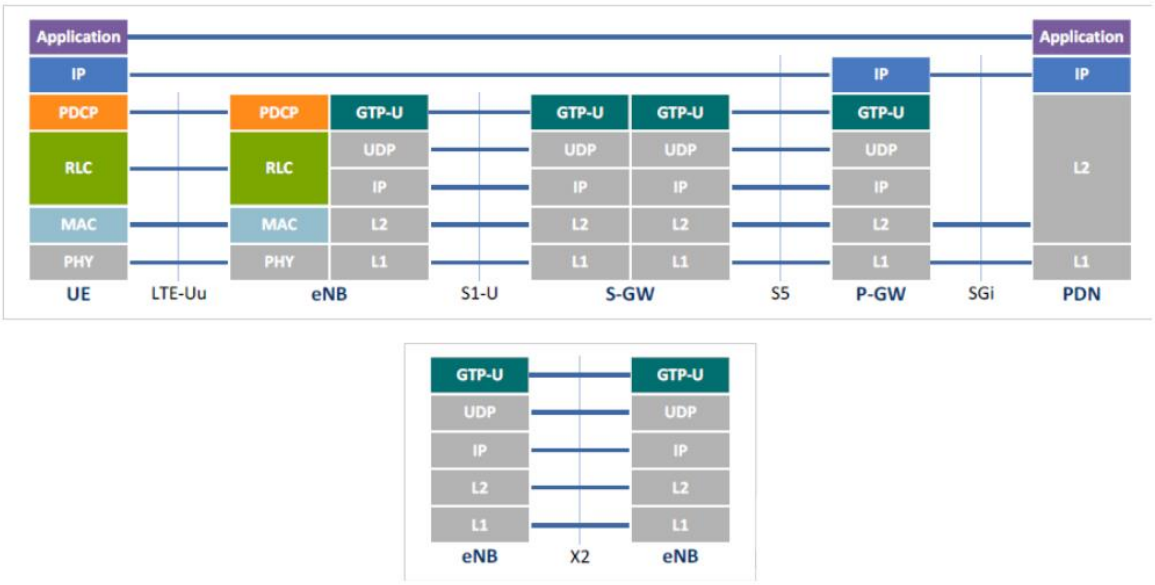


Figure I.8: piles de protocoles de l'utilisateur LTE.

- **X2 :** Facilitant la connexion entre deux ou plusieurs eNodeBs, l'interface X2 se divise en deux parties : X2-C pour le contrôle inter-eNodeBs, et X2-U pour les données utilisateur. La structure des interfaces X2-C et X2-U est similaire à celle de l'interface S1
- **S5:** Connecte S-GW et P-Gw, il fournit la gestion de tunnels et de tunnel à l'utilisateur. Il est basé sur le protocole GTP et est utilisé pour connecter un P-GW non collocé pour la connectivité PDN, et le déplacement de S- GW en raison de la mobilité.[6]
- **SGi :** Il est responsable de la connexion du P-GW au réseau de données de paquets. En tant que fourniture pour les services IMS, un réseau de données de paquets peut être le réseau public ou privé externe d'un opérateur ou un réseau intra-opérateur.[6]

La figure 8 montre les piles de protocole de plan utilisateur pour le réseau LTE.

I.4.5- Handover en LTE :

La mobilité pose des défis significatifs pour LTE en termes de transfert et de handover. Comparativement à l'UMTS, LTE rencontre des difficultés accrues lors des transferts. LTE gère les transferts intra-LTE ainsi que ceux entre LTE et UTRAN, les réseaux d'accès radio LTE, GSM-EDGE (GERAN) et d'autres réseaux mobiles.

I.4.5.1- Mobilité inter-RAT :

Lorsqu'une UE est activée, elle effectue une recherche cellulaire pour localiser et choisir une cellule appropriée à loger.

La réélection cellulaire est un état de mode vide et le mécanisme de changement des cellules après une UE a été campé.[7]

Le transfert est un état de mode connecté qui se produit lorsque deux états connectés de technologies d'accès radio différentes ou identiques sont convertis. La réorientation est un processus qui change l'état de l'UE de connexion à inactivité, souvent à des fins de commutation complète (CSFB). Parce qu'un transfert n'est pas nécessaire et peut ne pas être pris en charge par le réseau ou l'UE dans le cas de CSFB, le redirection est la technique par défaut à utiliser. En outre, en raison de facteurs tels que la cellule de mesure interRAT / détection du retard, le déclencheur de 10 temps, l'initiation du transfert de réseau, et l'endroit où l'appel a été initié ou terminé, une redirection peut se produire avant le transfert dans certains cas Sesia [6]. La signalisation LTE et les transitions d'état sont illustrées à la figure 9.

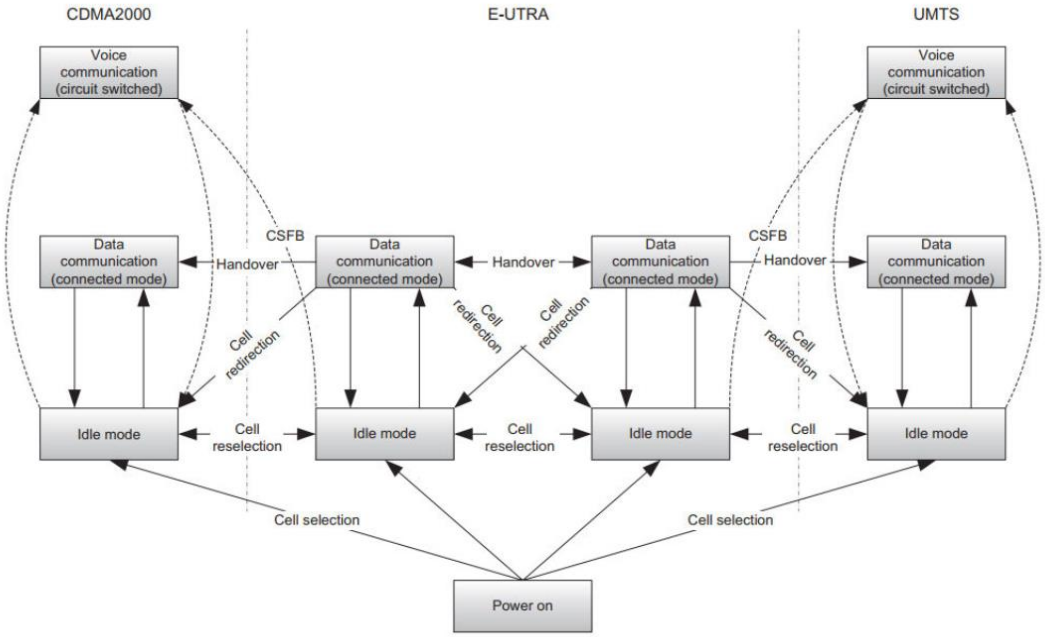


Figure I.9: Inter-RAT mobility procedures.

I.4.5.2- Mobilité vers la eNodeBs :

Pour assurer la mobilité vers les eNodeBs domestiques (HeNBs), de nombreuses fonctions du nœud source LTE RAN et du MME sont essentielles. Le nœud RAN source doit transmettre au MME non seulement l'identifiant global de la cellule E-UTRAN (ECGI), mais aussi l'identité du groupe d'abonnés fermé (CSG ID) et le mode d'accès du HeNB cible. Cela permet au MME de gérer l'accès à ce HeNB. Si le MME rejette le transfert, il envoie un message d'échec de la préparation du transfert, indiquant que le contrôle d'accès a échoué et que le HeNB cible est en mode d'accès fermé.

I.4.5.3- Livraison sans faille :

Si l'eNodeB source opte pour un mode de transfert sans interruption pour un flux de données spécifique, il indique à l'eNodeB de destination la nécessité d'établir un tunnel GTP pour faciliter la transmission descendante des données.

I.4.5.4- Handover sans perte :

Si la source eNodeB sélectionne le mode sans perte pour un porteur donné, les paquets de données utilisateur plan downlink qui ont été traités par le protocole de convergence de données de paquet (PDCP) sont conservés localement en mémoire tampon. Cela se produit parce qu'ils n'ont ni été envoyés ni reconnus par l'UE, mais ils seront redirigés vers l'interface X2.

I.4.6- Type d'accès radio LTE :

LTE offre plusieurs types d'accès radio pour les communications sans fil:

- **Accès Radio En Ligne Directe (Direct Radio Access):** Aussi connu sous le nom de FDD (Frequency Division Duplex) et TDD (Time Division Duplex), où les liaisons montantes et descendantes utilisent des fréquences différentes (FDD) ou sont séparées dans le temps (TDD).

Tableau I.9: Différence entre le LTE-FDD [8].

PARAMETRE	FDD	TDD
Spectre	Spectre aligné	Spectre inégalé
Trafic	L'asymétrie dépend du spectre disponible	L'asymétrie est réglable dynamiquement
Séparation fréquence/temps	Besoin d'une bande de garde	Besoin d'une période de garde
Interférences intra-système	Une situation inattendue	La synchronisation de eNodeBs est requise
Taille de la cellule	Pour les cellules grandes ou petites	Ajuster les petites cellules en raison de la période de garde
Coûts du matériel	Un duplex complexe entraîne un coût élevé	Il n'y a pas de coût significatif

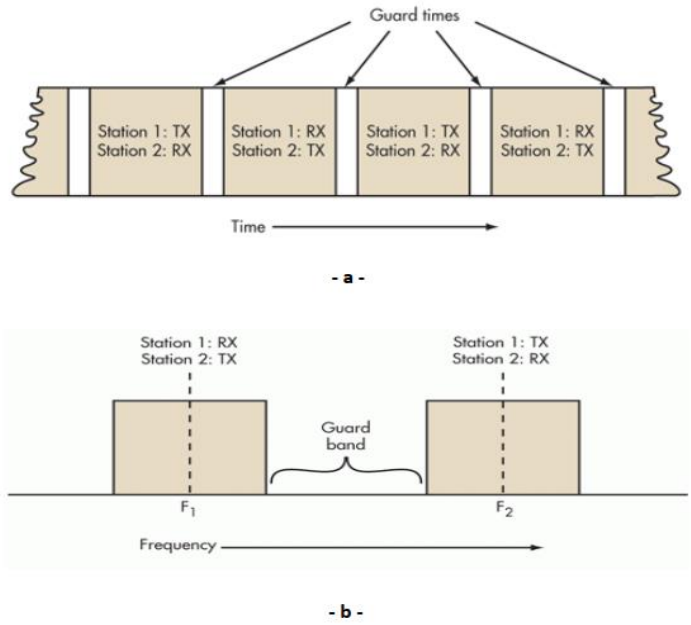


Figure I.10: Type d'accès radio LTE. a) mode TDD, b) mode FDD.

I.4.7- Optimisation LTE et analyse KPI :

Typiquement, les KPI en LTE peuvent être divisés en plusieurs sous-catégories :

- **Accessibilité :** Employé pour évaluer si les services requis par les utilisateurs peuvent être accessibles dans des conditions spécifiques, ainsi que la qualité de disponibilité lorsque les utilisateurs en ont besoin. Par exemple, un utilisateur peut solliciter l'accès au réseau, un appel vocal, ou un échange, etc.
- **Retenabilité :** Utilisé pour évaluer dans quelle mesure un réseau peut maintenir la connexion d'un utilisateur ou lui fournir des services.
- **Mobilité :** Employé pour évaluer la capacité d'un réseau à gérer le déplacement de l'utilisateur tout en maintenant un service continu.
- **Intégrité :** Utilisé pour évaluer la fiabilité ou la sincérité d'un réseau vis-à-vis de ses utilisateurs, notamment en ce qui concerne le débit, la latence et le nombre d'utilisateurs pris en charge.
- **Disponibilité :** Employé pour déterminer si un réseau est prêt, disponible ou adapté aux utilisateurs pour l'utilisation des services**.**
- **Utilisation :** Utilisé pour évaluer si la capacité d'un réseau a été atteinte et si ses ressources sont épuisées.

Le tableau 10 résume en détail le KPI LTE et ses indicateurs.

Tableau I.10: KPI du RAN LTE.

Tableau I.11: KPI du RAN LTE.

LTE KPI	INDICATEURS
ACCESSIBILITE	Taux de réussite de configuration RRC. Taux de réussite de configuration ERAB.
RETENABILITE	aux de chute d'appel. Taux de baisse des appels de service.
MOBILITE	Taux de réussite du transfert intra-fréquence. Taux de réussite du transfert interfréquence. Taux de réussite des transferts Inter-RAT (LTE to WCDMA).
INTEGRITE	Débit IP E-UTRAN. Débit IP en DL. Latence IP E-UTRAN.
UTILISATION	Utilisation moyenne active du porteur EPS dédié.

I.5- conclusion :

Les réseaux mobiles de la 2G à la 4G ont été le théâtre d'innovations continues, chacune apportant des améliorations majeures en termes de performance, de capacité et de services offerts. La 2G a introduit la communication numérique et les SMS, la 3G a permis les connexions Internet mobiles rapides et les services multimédias, tandis que la 4G a offert des vitesses ultra-rapides et une faible latence. Cette évolution a non seulement transformé la manière dont nous communiquons, mais a également ouvert la voie à de nouvelles applications et services qui continuent de façonner notre société numérique. En regardant vers l'avenir, les technologies de cinquième génération (5G) promettent de repousser encore plus loin les limites de ce qui est possible, ouvrant la porte à une nouvelle ère de connectivité et d'innovation.

CHAPITRE II :

II.1-introduction :

L'évolution rapide des technologies numériques a révolutionné divers aspects de notre vie quotidienne, de la manière dont nous interagissons avec les appareils à la façon dont nous prenons des décisions basées sur les données. Parmi ces technologies, l'intelligence artificielle (IA), le machine Learning (ML), le deep Learning (DL) et le transfer Learning se distinguent comme des piliers essentiels de cette transformation numérique. Bien que souvent utilisés de manière interchangeable, ces concepts ont des significations distinctes et des applications spécifiques. Dans cette introduction, nous explorerons les fondements de l'IA, du ML, du DL et du transfer Learning, en soulignant leurs différences et leurs interconnexions.

L'intelligence artificielle (IA) est un vaste concept associé aux machines qui peuvent résoudre des tâches complexes tout en démontrant des traits évidents d'intelligence. Le deep Learning (ou apprentissage profond) et le machine Learning (ou apprentissage automatique) sont des sous-catégoriesd'IA.[9]

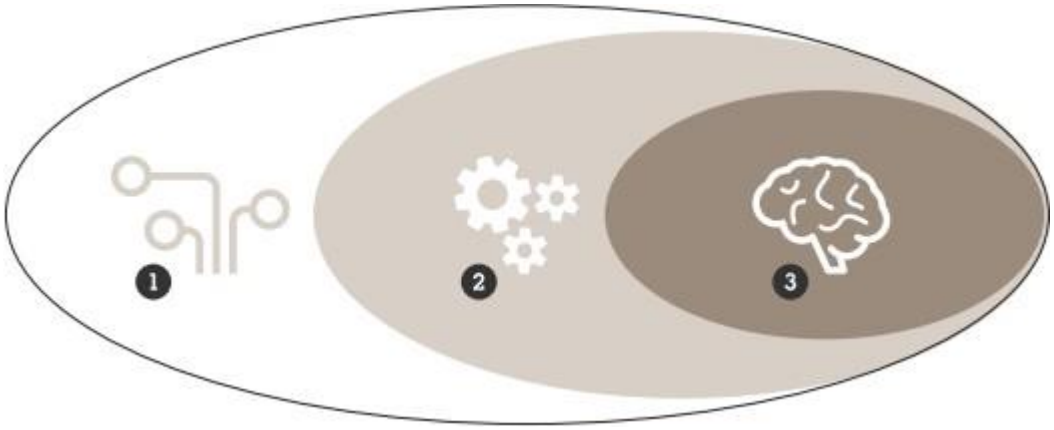


Figure II. 1: Les sous-catégories de L'IA.

1: Intelligence artificial
2: Machine learning
3: Deep learning

II.2-Deep Learning :

L'apprentissage profond, également connu sous le nom de deep Learning, est une branche de l'intelligence artificielle (IA) qui vise à modéliser et à comprendre des données complexes en utilisant des architectures de réseaux de neurones artificiels à plusieurs couches. Cette approche tire son nom de la profondeur des architectures de réseaux de neurones, qui peuvent

comporter plusieurs couches de traitement des données. L'essence de l'apprentissage profond réside dans sa capacité à apprendre des représentations de données à différents niveaux d'abstraction, en découvrant des caractéristiques hiérarchiques à partir de données non structurées ou peu structurées.

L'un des aspects les plus remarquables de l'apprentissage profond est sa capacité à effectuer automatiquement la sélection des caractéristiques à partir des données brutes, éliminant ainsi le besoin d'une ingénierie des caractéristiques manuelle souvent laborieuse dans les méthodes traditionnelles d'apprentissage automatique. Les réseaux de neurones profonds sont capables d'apprendre des modèles complexes et abstraits à partir de données, ce qui leur permet de surpasser souvent les méthodes traditionnelles dans des tâches telles que la classification d'images, la reconnaissance vocale, la traduction automatique, et bien d'autres encore.

L'apprentissage profond a connu une montée en puissance significative au cours des dernières années, en grande partie grâce aux progrès dans le matériel informatique et aux innovations dans les algorithmes d'entraînement. Cette discipline est devenue un pilier central de nombreuses applications d'intelligence artificielle et continue d'évoluer rapidement, ouvrant la voie à de nouvelles avancées technologiques et à des capacités de traitement des données encore plus puissantes.[10]

II.2.1-Définition :

Le deep Learning est une version améliorée du machine Learning dans laquelle l'extraction de Caractéristiques et la façon dont on combine ces caractéristiques, dans des structures profondes de règles pour produire une sortie, sont apprises d'une façon guidée par les données. L'algorithme peutautomatiquement définir les caractéristiques à rechercher dans les données d'apprentissage. Il peut également apprendre des structures très profondes de combinaisons chaînées de caractéristiques.

Le cœur des algorithmes utilisés en deep Learning est inspiré par le fonctionnement des neurones et l'utilisation de ceux-ci par le cerveau pour former un niveau supérieur de connaissances en combinantles sorties neuronales dans une hiérarchie profonde, ou un réseau de règles chaînées. Le cerveau est unsystème dans lequel les combinaisons elles-mêmes sont également formées par les neurones, supprimant la distinction entre l'extraction des caractéristiques et la combinaison des caractéristiques, les rendant identiques d'une certaine façon.

Ces structures sont simulées par les chercheurs dans ce qu'on appelle les réseaux de neurones artificiels, ce qui représente le type d'algorithme le plus utilisé endeep Learning. Voir l'annexe du présent document pour un aperçu rapide des réseaux de neurone.

À l'aide des algorithmes de deep Learning, il est possible de créer des détecteurs visuels complexes et de les former automatiquement à détecter des objets très complexes, quelles que soientl'échelle, la rotation et les autres variations et apprendre sur ces caractéristiques petites à petit à travers chaque couche avec une intervention humaine minime.

La raison derrière cette souplesse réside dans le fait que les systèmes de deep Learning peuvent apprendre à partir d'un plus grand nombre de données, d'une plus grande variété, que les systèmes demachine Learning classiques. Dans la plupart des cas, ils seront beaucoup plus performants que les algorithmes de vision par ordinateur créés à la main. Cela rend le deep Learning particulièrement adaptéaux problèmes complexes dans lesquels la combinaison de caractéristiques ne peut être facilement réalisée par des experts humains, telles que la classification d'images, le traitement du langage et la détection d'objet.[11]

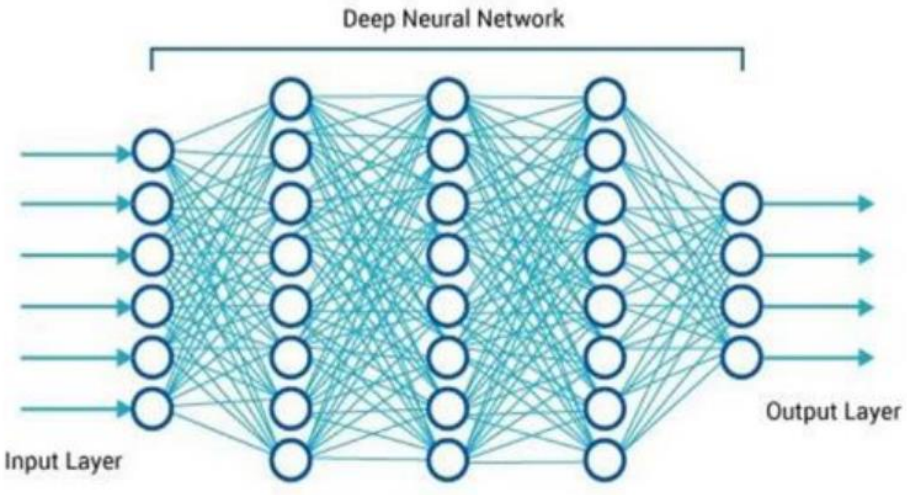


Figure II. 2: illustratif Schéma de DL avec plusieurs couches.

II.2.2-Historique :

L'idée du Deep Learning n'est pas une idée récente, mais elle date en réalité des années 1980,plus particulièrement suite aux travaux de réseaux de neurones multicouches et aux travaux de certains pionniers du machine Learning et du Deep Learning comme le français Yann Le Cun. En collaboration avec deux autres informaticiens, Kunihiko Fukushima et Geoffrey Hinton, ils mettent au point un type d'algorithme particulier appelé Convolutional neural network (CNN).

Bien que cette approche donne des résultats, ses progrès et son évolution sont limités par les progrès technologiques en matière de micro-processeurs, de puissance de calculs, et du manque d'accessibilités à des données afin de pouvoir entraîner les neurones. Cependant certains chercheurs ont continué à travailler sur ce modèle pendant environ deux décennies et, avec l'aide des évolutions en matière de technologies, mais surtout avec la disponibilité toujours plus grande de données, ont pu améliorer cette technique.

Afin de développer un système d'apprentissage performant, il faut pouvoir l'exercer et cela requiert un nombre important de données à tester. C'est dans ce contexte qu'en 2007 le STANFORD VISION LAB, avec Fei-Fei Li à sa tête, développent un agrégateur d'images où sont consignés et étiquetés quelques millions de photos : ImageNet.

En 2010, ImageNet regroupe 15 000 000 d'images toutes catégorisées en fonction de leurs caractéristiques propres (véhicules, animaux, ...) .

En 2012, le Deep Learning est remis au goût du jour avec un succès retentissant au ImageNet Large Scale Visual Recognition Challenge (ILSVRC) qui est un concours annuel de reconnaissance d'image fondée par l'université de Stanford, dans le cadre de son laboratoire STANFORD VISION LAB. Plusieurs équipes de chercheurs en informatique s'affrontent dans ce concours tous les ans afin de décerner la victoire au programme ayant eu le plus faible taux d'échec. Et alors que les algorithmes d'apprentissage profond sont absents de la compétition, en 2012 c'est bel et bien un algorithme de Deep Learning qui va remporter l'édition 2012 à la surprise générale .

Au cours des années 2020 et au-delà, le deep Learning continue de se développer et de s'intégrer dans divers secteurs industriels. Les avancées dans des domaines tels que le transfert d'apprentissage et l'apprentissage par renforcement ouvrent de nouvelles perspectives pour l'avenir de l'IA. Malgré les progrès impressionnants, des défis subsistent, notamment en matière d'éthique, de sécurité et d'interprétabilité des modèles, mais le deep Learning demeure au cœur de l'innovation technologique et promet un avenir passionnant.[12]

II.2.3- Pour quoi le choix deep Learning :

Tout d'abord les différents algorithmes du deep Learning ne sont apparus qu'à l'échec de l'apprentissage automatique tentant de résoudre une grande variété de problèmes de l'intelligence artificielle (l'IA) :

- Afin d'améliorer le développement des algorithmes traditionnels dans de telles tâches de l'IA.
- De développer une grande quantité de données telle que les big data.

➢ De s'adapter à n'importe quel type de problème

➢ D'extraire les caractéristiques de façon automatique.[13]

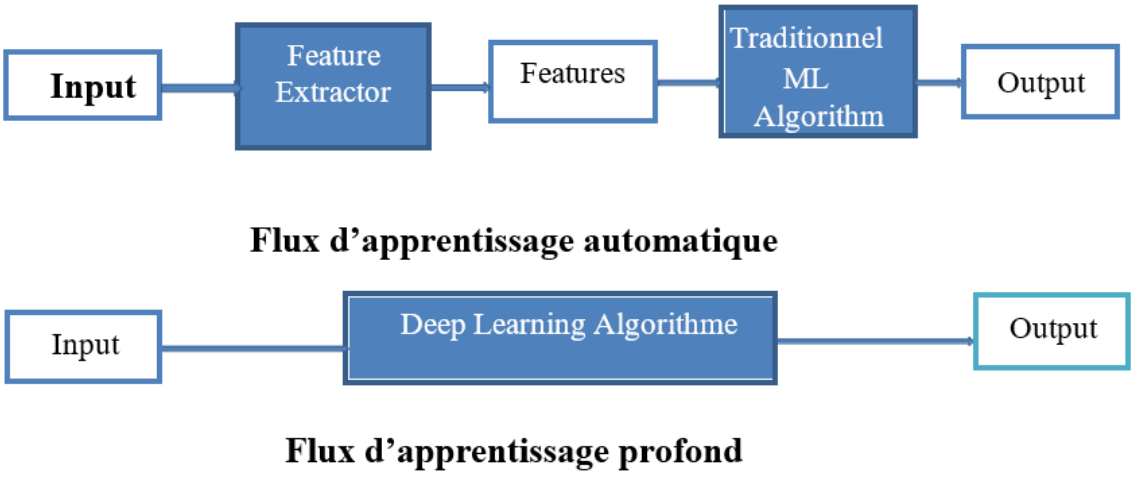


Figure II. 3: Comparaison entre la machine Learning et le Deep Learning.

II.2.4-Les différentes Architectures du Deep Learning :

Bien qu'il existe un grand nombre de variantes d'architectures profondes. Il n'est pas toujours possible de comparer les performances de toutes les architectures, car elles ne sont pas toutes évaluées sur les mêmes ensembles de données. Le Deep Learning est un domaine à croissance rapide, et de nouvelles architectures, variantes ou algorithmes apparaissent toutes les semaines.

II.2.4.1-Les réseaux de neurones convolutifs :

Convolutional Neural Network (CNN) (réseaux de neurones convolutifs) sont un type de réseau de neurones spécialisés pour le traitement de données ayant une topologie semblable à une grille. Qui se sont avérés très efficaces dans des domaines tels que la reconnaissance et la classification d'images et vidéos. CNN a réussi à identifier les visages, les objets, panneaux de circulation et auto-conduite des voitures [14]. Récemment, les CNN ont été efficaces dans plusieurs tâches de traitement du langage naturel (telles que la classification des phrases) [15].[16]. [17].

Dans le ML, un réseau convolutif est un type de réseau de neurones feed-forward, il a été inspiré par des processus biologiques [18]. Il existe quatre (4) principales opérations illustrées dans le CNN à savoir :

- La couche convolution
- La couhe Rectified Linear Unit
- La couche Pooling
- La couche entièrement connectée

II.2.4.2 -Réseau de neurones récurrents :

L'idée derrière les RNN est d'utiliser des informations séquentielles. Dans un réseau neuronaltraditionnel, nous supposons que toutes les entrées (et les sorties) sont indépendantes les unes des autres. Mais pour de nombreuses tâches, c'est une très mauvaise idée. Si on veut prédirele prochain mot dans une phrase, il faut connaître les mots qui sont venus avant. Les RNN sont appelés récurrents, car ils exécutent la même tâche pour chaque élément d'une séquence, la sortie étant dépendante des calculs précédents.

Une autre façon de penser les RNN est qu'ils ont une « mémoire » qui capture l'information sur ce qui a été calculé jusqu'ici. En théorie, les RNN peuvent utiliser des informations dans des séquences arbitrairement longues, mais dans la pratique, on les limite à regarder seulement quelques étapes en arrière. [19].[20].[21].[22]. Il est utilisé pour :

- La modélisation du langage et génération de texte
- La traduction automatique
- La reconnaissance vocale
- Et la description des images

II.2.4.3-Modèle génératif :

Si les modèles discriminatifs comme (CNN, RNN) sont utilisés pour prédire les données du label et de l'entrée, tant disque le modèle génératif décrit comment générer les données, il apprend et fait des prédictions en utilisant la loi de Bayes [23].

Cependant les modèles génératifs sont capables de bien plus que la simple classification comme par exemple générer de nouvelles observations.Voici quelques exemples de modèle génératif :

- Boltzmann Machines [24].
- Restricted Boltzmann Machines [25].[26].
- Deep Belief Networks [27].

• Deep Boltzmann Machines [28].[29].

• Generative Adversarial Networks• Generative Stochastic Networks [30].

• Adversarial autoencoders [31].

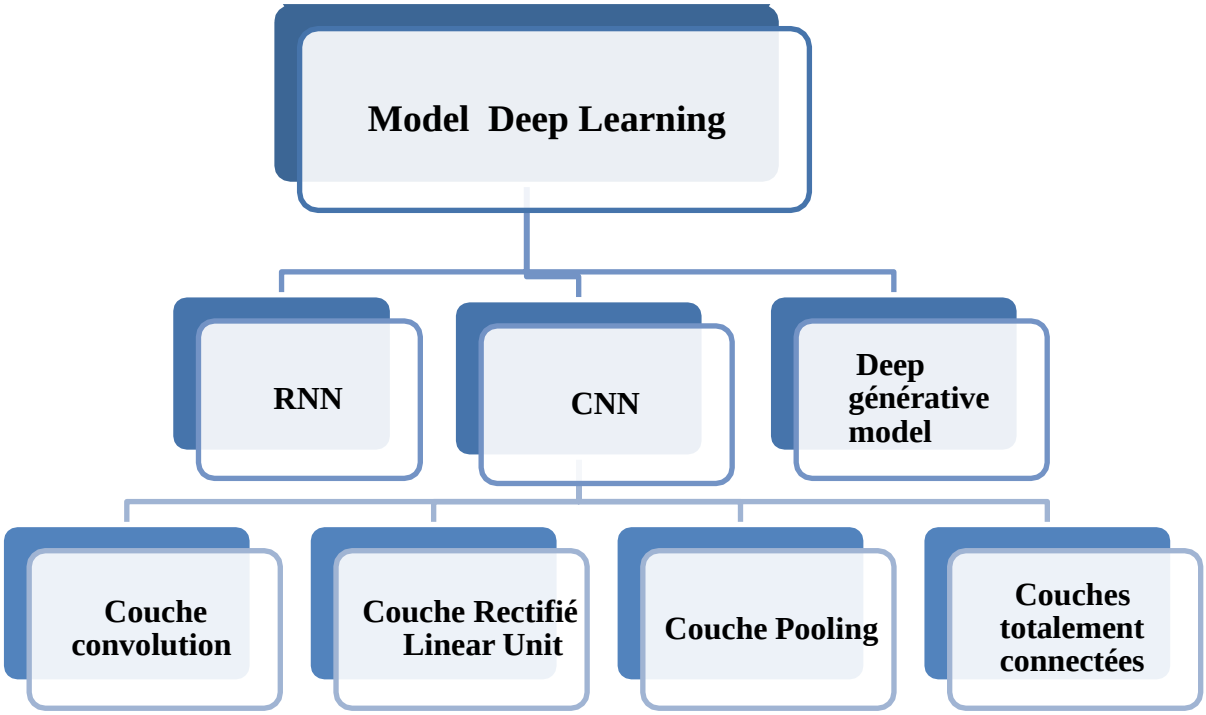


Figure II. 4: Différents modèles du Deep Learning.

II.2.5- Exemples d'application de Deep Learning :

Les applications du Deep Learning sont utilisées dans divers secteurs, de la conduite automatisée aux dispositifs médicaux. [32]

Grace au deep Learning nous pouvons maintenant

- Faire une colorisation des images en noir et blanc.[33]
- Ajouter des sons à des films silencieux. [34]
- Faire de la traduction automatique. [35]
- Faire de classification des objets en photographies. [36]
- Générer d'écriture automatique. [37]
- Génération de légende d'image. [38]
- Jeu automatique. [39]

II.3- Machine Learning :

Le machine Learning est un sous-ensemble de l'IA qui utilise les algorithmes d'apprentissage statistique Pour créer des systèmes capables d'apprendre et de se développer automatiquement pendantla formation sans y être explicitement programmés.

Dans cette partie, nous faisons la distinction entre la programmation traditionnelle et le machineLearning dans le contexte de la vision par ordinateur, cette discipline qui permet aux ordinateurs de comprendre ce qu'il se passe dans une scène grâce à l'analyse d'images et de vidéo.

La vision par ordinateur à programmation traditionnelle est basée sur des méthodes qui calculent les caractéristiques d'une image, par exemple, les programmes informatiques qui recherchent les bordsprononcés et les repères de sommet. Ces caractéristiques doivent être définies manuellement par un développeur d'algorithme qui connaît les éléments importants dans les données d'image. Le développeur combine alors ces caractéristiques de l'algorithme pour conclure ce qui se trouve dans la scène.

Les algorithmes de machine Learning créent automatiquement un modèle mathématique à l'aided'un nombre considérable de données d'échantillon, les données d'apprentissage, pour acquérir la Capacité de prendre des décisions en calculant les résultats sans y être particulièrement programmés.Les caractéristiques sont toujours créées à la main mais la façon dont les caractéristiques sont combinées est apprise par l'algorithme lui-même par l'exposition à un grand nombre de données d'apprentissage étiquetées ou annotées. Dans ce livre, nous appelons cette technique d'utilisation de caractéristiques créées à la main dans des combinaisons apprises, le machine learning classique.

En d'autres termes, pour une application de machine learning, nous devons apprendre à l'ordinateur à acquérir le programme que nous souhaitons. Les données sont collectées, puis annotées par l'homme, parfois assisté par des pré-annotations effectuées par des ordinateurs serveurs. Le résultat est alimenté dans le système et ce processus continu jusqu'à ce que l'application ait appris suffisammentà détecter ce que nous souhaitons qu'elle détecte.[9]

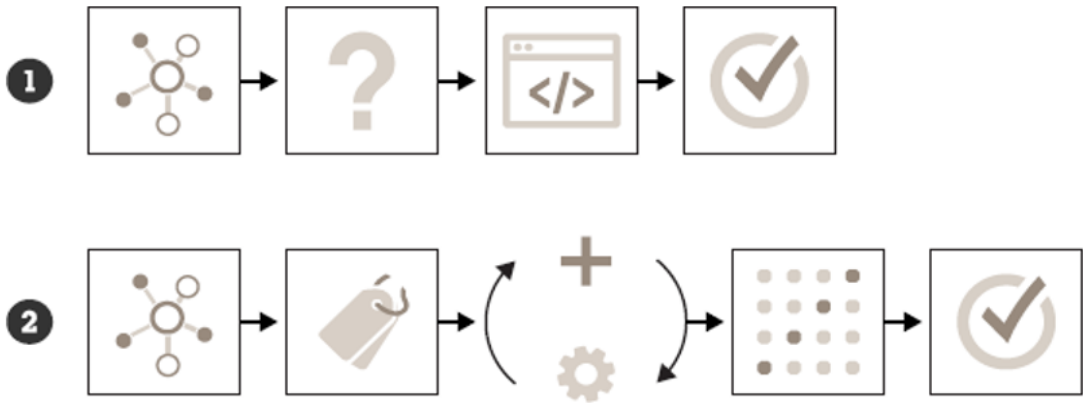


Figure II. 5: comparaison entre programme traditionnelle et machine learning.

1.Programmation traditionnelle :

Les données sont collectées ; Les critères du programme sont définis ; Le programme est codé(par L'homme) ; Terminé.

2. Machine learning :

Les données sont collectées ; Les données sont étiquetées ; Le modèle subit une procédureD'apprentissage itérative ; Le modèle appris finalisé devient le programme ; Terminé.

L'avantage de l'IA sur la programmation traditionnelle, dans le cadre de la création d'un programme division par ordinateur, réside dans la possibilité de traiter un très grand nombre de données. Un ordinateur peut passer en revue des milliers d'images sans perdre sa concentration, alorsque les programmateurs humains se fatigueront et perdront leur concentration au bout d'un moment.

Ainsi, l'IA peut rendre l'application considérablement plus précise. Cependant, plus l'application estcompliquée, plus il sera difficile pour la machine de produire le résultat attendu.[9]

II.4- Transfer learning :

L'apprentissage par transfert (Transfer Learning en anglais) est une technique d'apprentissage automatique dans laquelle les connaissances acquises à partir d'une tâche ou d'un ensemble de données sont utilisées pour améliorer les performances de modèles sur une autre tâche connexe et/ou sur différents ensembles de données.1 En d'autres termes, le transfert utilise ce qui a été appris dans un cadre afin d'améliorer la généralisation dans un autre. En effet, il est particulièrement attrayant pour ce dernier étant donné la grande quantité de données nécessaires pour créer des réseaux neuronaux profonds.[40]

Les processus d'apprentissage traditionnels construisent un nouveau modèle pour chaque nouvelle tâche, sur la base des données étiquetées disponibles. C'est parce que les algorithmes traditionnels d'apprentissage automatique supposent que les données de formation et de test proviennent du même espace de caractéristiques, et donc si la distribution de données change, ou si le modèle entraîné est appliqué à un nouvel ensemble de données, les utilisateurs doivent reprendre un nouveau modèle à partir de zéro, même s'ils tentent une tâche similaire à celle du premier modèle (e.g. sentiment analysis classifier of movie reviews versus song reviews). Les algorithmes d'apprentissage de transfert, cependant, prennent des modèles ou des réseaux déjà formés comme point de départ. Il applique ensuite les connaissances du modèle acquises dans une tâche source initiale ou des données (p. ex. classification des critiques de films) vers une nouvelle tâche cible ou les données, mais connexes. (e.g. classifying song reviews).[41]

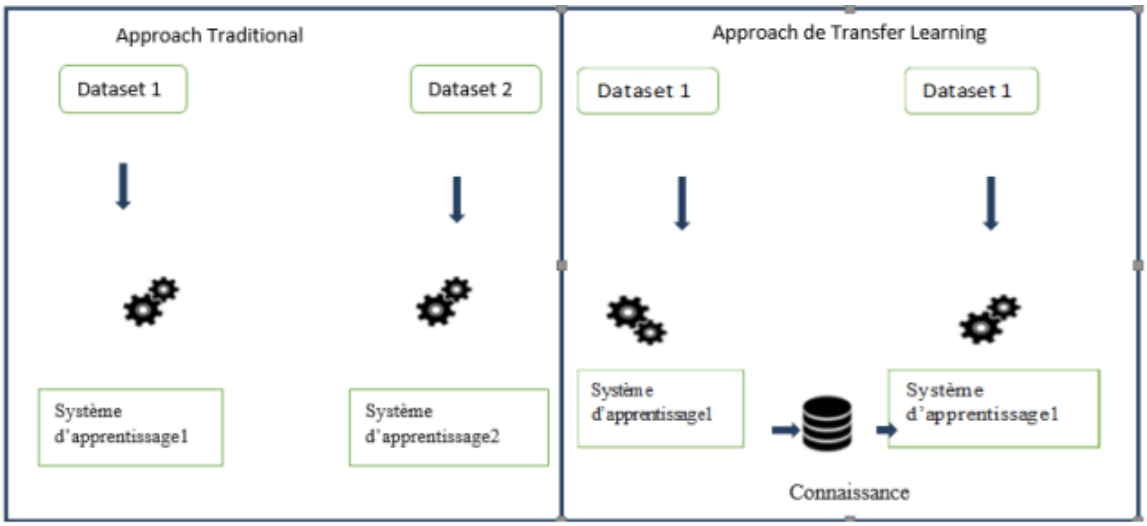


Figure II. 6: Transfer Learning.

II.4.1- Histoire du Transfer Learning:

• En 1976, Stevo Bozinovski et Ante Fulgosi ont publié un article traitant explicitement de l'apprentissage par transfert dans la formation aux réseaux de neurones L'article donne un modèle mathématique et géométrique de l'apprentissage par transfert. En 1981, un rapport a été présenté sur l'application de l'apprentissage par transfert dans la formation d'un réseau de neurones sur un ensemble de données d'images représentant des lettres de terminaux informatiques. L'apprentissage par transfert positif et négatif a été démontré expérimentalement.

• En 1993, Lorien Pratt a publié un article sur le transfert dans l'apprentissage automatique , formulant l'algorithme de transfert basé sur la discriminabilité (DBT).

• En 1997, Pratt et Sebastian Thrun ont édité un numéro spécial de Machine Learning consacré à l'apprentissage par transfert, et en 1998, le domaine avait progressé pour inclure l' apprentissage multi-tâches , ainsi qu'une analyse plus formelle de son fondations. Apprendre à apprendre, édité par Thrun et Pratt, est une revue de 1998 sur le sujet.

• L'apprentissage par transfert a également été appliqué dans les sciences cognitives , avec Pratt en tant qu'invité d'édition d'un numéro de Connection Science sur la réutilisation des réseaux de neurones par transfert en 1996

• Andrew Ng a déclaré dans son tutoriel NIPS 2016 que le TL sera le prochain moteur du succès commercial du ML après un apprentissage supervisé pour souligner l'importance du TL.[42]

II.4.2- Comment utiliser l'apprentissage par transfert :

Vous pouvez utiliser l'apprentissage par transfert sur vos propres problèmes de modélisation prédictive.[43]

Deux approches courantes sont les suivantes :

-Développer une approche modèle

-Approche de modèle préformé.

a)Développement d'une approche modèle :

1-Sélectionnez Tâche source. Vous devez sélectionner un problème de modélisation prédictive connexe avec une abondance de données où il existe une relation entre les données d'entrée, les données de sortie et/ou les concepts appris lors du mappage des données d'entrée aux données de sortie.

2- Développer le modèle source. Ensuite, vous devez développer un modèle habile pour cette première tâche. Le modèle doit être meilleur qu'un modèle naïf pour garantir qu'un certain apprentissage des fonctionnalités a été effectué.

3- Réutiliser le modèle. L'ajustement du modèle sur la tâche source peut ensuite être utilisé comme point de départ pour un modèle sur la deuxième tâche d'intérêt. Cela peut impliquer d'utiliser tout ou partie du modèle, selon la technique de modélisation utilisée.

4- Modèle d'accord. En option, le modèle peut devoir être adapté ou affiné sur les données de pair entrée-sortie disponibles pour la tâche d'intérêt.

b) Approche de modèle pré-formé :

1- Sélectionnez Modèle source. Un modèle source pré-entraîné est choisi parmi les modèles disponibles. De nombreux instituts de recherche publient des modèles sur des ensembles de données volumineux et complexes qui peuvent être inclus dans le pool de modèles candidats parmi lesquels choisir.

2- Réutiliser le modèle. Le modèle préformé peut ensuite être utilisé comme point de départ pour un modèle sur la deuxième tâche d'intérêt. Cela peut impliquer d'utiliser tout ou partie du modèle, selon la technique de modélisation utilisée.

3- Modèle d'accord. En option, le modèle peut devoir être adapté ou affiné sur les données de pair entrée-sortie disponibles pour la tâche d'intérêt. Ce deuxième type d'apprentissage par transfert est courant dans le domaine de l'apprentissage en profondeur

II.4.3- Type de Transfer Learning:

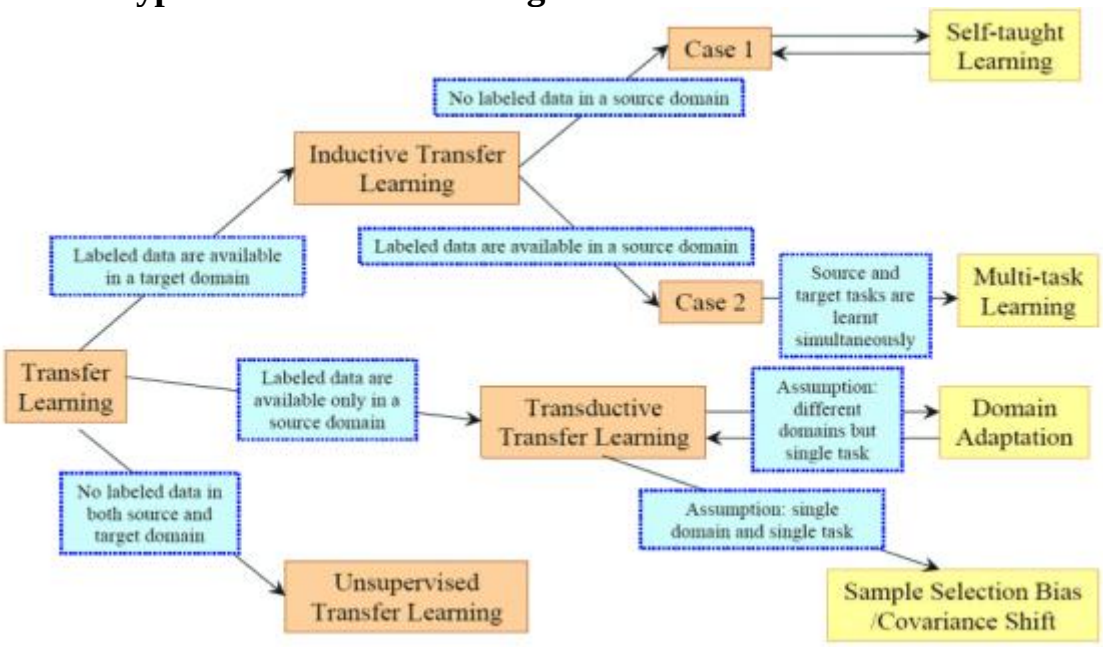


Figure II. 7 Type de transfert Learning. [51]

a) Apprentissage par transfert inductif :

Dans cette configuration, les domaines source et cible sont les mêmes (même données),mais les tâches source et cible sont différentes mais proches. L'idée consiste alors à utiliser lesmodèles existants pour réduire de manière avantageuse le champ d'application des modèles possibles (biais de modèle) comme illustré dans la figure ci-dessous.[44]

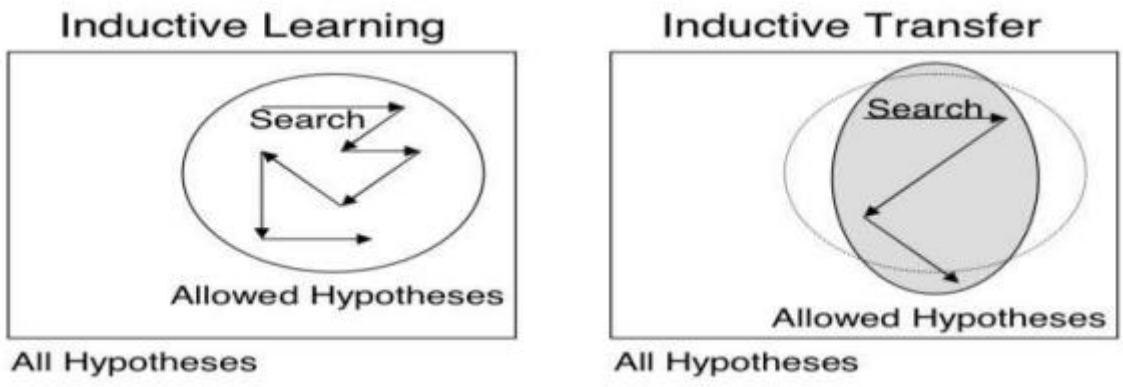


Figure II. 8 : Apprentissage inductif et transfert inductif.

b) Apprentissage par transfert non supervisé :

Comme dans le cas de l'apprentissage par transfert inductif, les domaines source et cible sont similaires, mais les tâches sont différentes. Toutefois, les données des deux domaines ne sont pas labellisées.

Il est souvent plus facile d'obtenir de grandes quantités de données non labellisées, à partir de bases de données et de sources sur le web par exemple, que des données labellisées. C'est pourquoi l'idée d'utiliser l'apprentissage non supervisé en combinaison avec le Transfer Learning suscite un grand intérêt.

À titre d'exemple, le Self-taught clustering est une approche qui permet de réaliser le clustering de petites collections de données cibles non labellisées, avec l'aide d'une grande quantité de données sources non labellisées. Cette approche s'avère plus performante que les approches de pointe traditionnellement utilisées, lorsque les données cibles sont labellisées de manière non pertinente.[44]

c) Apprentissage par transfert transductif :

Dans cette configuration, les tâches sources et cibles sont similaires, mais les domaines correspondants sont différents soit en termes de données ou de distributions de probabilités marginales.

Par exemple, les modèles de NLP, tels que ceux utilisés pour l'étiquetage morphosyntaxique de mots, Part-Of-Speech Tagger (POS Tagger) en anglais, sont généralement entraînés et testés sur des données d'actualité comme celles du Wall Street Journal. Ils peuvent être adaptés aux données issues des réseaux sociaux dont le contenu est différent mais proche de celles des journaux.[44]

II.4.4- Méthodes d'évaluation des réseaux IA :

Dans cette section, nous allons aborder les méthodes d'évaluation qui peuvent être utilisées pour évaluer les performances d'un système de détection d'anomalies (ADS) dans le réseau 4G.

II.4.5- Matrice de confusion :

Une matrice de confusion est un tableau qui regroupe les résultats de l'application d'un algorithme d'apprentissage automatique (ML). Dans le cas de la détection d'anomalies (et toute classification binaire en général), la matrice de confusion contient quatre quantités :

- **Vrais positifs (VP)** : Un VP est une anomalie correctement étiquetée par l'ADS.
- **Faux positifs (FP)** : Un FP (également appelé erreur de type I) est une valeur normale étiquetée à tort par l'ADS comme une anomalie.
- **Vrais négatifs (VN)** : Un VN est une valeur normale correctement étiquetée par l'ADS.
- **Faux négatifs (FN)** : Un FN (également appelé erreur de type II) est une anomalie étiquetée à tort par l'ADS comme une valeur normale.

Tableau II. 1: Matrice de confusion.

		Planned	
		Positive	Negative
Real	Positive	TP	FN
	Negative	FP	TN

Comme le montre le tableau 1, la matrice de confusion donne un aperçu de la performance d'un ADS. De nombreuses mesures de rendement ont été tirées de la matrice de confusion pour évaluer l'exactitude des résultats.

II.4.6- Métriques d'évaluation :

Les mesures suivantes permettent d'évaluer l'exactitude d'un ADS [45] :

spécificité : Appelé aussi TNR (True Negative Rate), il mesure la proportion de points normaux qui sont correctement étiquetés.

$$TNR = \frac{TN}{TN + FP}$$

précision : également appelée valeur prédictive positive (PPV), elle mesure la proportion d'anomalies correctement étiquetées parmi tous les points prédits comme anomalies.

$$PPV = \frac{TP}{TP + FP}$$

Cette mesure quantifie la pertinence des points détectés comme anomalies.

rappel : également appelé sensibilité ou TPR (True Positive Rate), il mesure la proportion d'anomalies qui sont correctement étiquetées.

$$TPR = \frac{TP}{TP + FN}$$

Cette mesure quantifie la capacité d'un ADS à détecter les anomalies existantes.

fallout : Appelé aussi FPR (False Positive Rate), il mesure la proportion de faux positifs parmi tous les points normaux.

$$FPR = \frac{FP}{FP + TN}$$

Taux de faux négatifs (FNR): est la proportion d'anomalies non détectées.

$$FNR = \frac{FN}{FN + TP}$$

précision (ACC): est la proportion des points correctement étiquetés par l'ADS.

$$\text{Précision(ACC)} = \frac{TN + TP}{TN + TP + FN + FP}$$

La spécificité et le résultat sont complémentaires. Ils mesurent la capacité du système à reconnaître un point normal. De même, le rappel et le FNR sont complémentaires.
Ils mesurent la capacité du système à détecter un point anormal.

TNR + FPR = 1
TPR + FNR = 1

II.4.7-Courbes d'évaluation :

II.4.7.1-La courbe de rappel de précision :

La courbe Precision-Recall (PR) est une autre façon d'évaluer la qualité d'un ADS [50]. La courbe PR affiche le TPR comme une fonction du PPV. elle vise à montrer le compromis entre détecter toutes les anomalies et avoir peu de faux positifs.

Cependant, comme le nombre d'anomalies est généralement très faible par rapport au nombre de cas normaux, le RFP peut être très proche de 0 et ses variations peuvent être imperceptibles. C'est pourquoi l'utilisation de PPV est plus judicieuse.

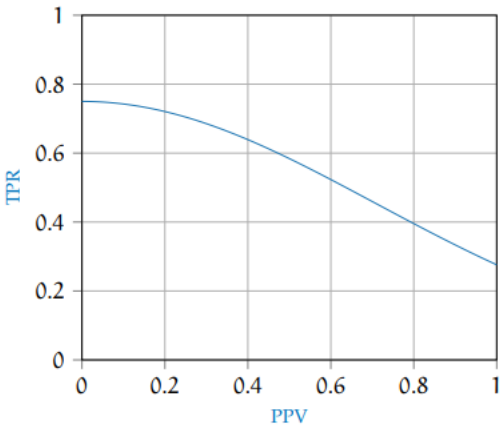


Figure II. 9: Exemple d'une courbe PR.

II.5-Conclusion :

L'intelligence artificielle, le machine learning, le deep learning et le Transfer learning représentent des étapes cruciales dans l'évolution des technologies informatiques. Alors que l'IA fournit le cadre théorique et les objectifs globaux, le ML et le DL offrent des approches pratiques pour atteindre ces objectifs en permettant aux machines d'apprendre et de s'adapter à partir des données. Le Transfer learning, quant à lui, optimise ce processus en transférant des connaissances entre différentes tâches, augmentant ainsi l'efficacité et réduisant les besoins en données. La synergie entre ces domaines continue de propulser des innovations qui ont un impact profond sur divers secteurs, de la santé et la finance à l'industrie et le divertissement. En comprenant les distinctions et les connexions entre l'IA, le ML, le DL et le TL, nous pouvons mieux appréhender le potentiel futur de ces technologies et leur rôle dans la transformation de notre monde.

CHAPITRE III :

III.1- Introduction :

Dans ce chapitre, nous introduisons une solution proposée pour détecter les anomalies dans les réseaux 4G, nommée LTE Transfert Learning Network (LTE_TL_NET). Nous abordons d'abord le problème de la détection des anomalies dans les réseaux 4G, puis nous précisons l'objectif de ce travail : obtenir une détection du système avec une faible marge d'erreur, tant pour les situations normales qu'anormales. Nous détaillons ensuite la base et l'architecture de notre solution. Par la suite, nous démontrons la validité et la robustesse de notre approche en la comparant à certaines techniques de référence. Enfin, nous présentons les principaux résultats obtenus à partir des tests de données sur les réseaux 4G, confirmant que notre solution satisfait aux exigences de précision. Ce chapitre se conclut par une brève discussion sur les perspectives de recherche futures.

III.1.1 Motivation :

Les compagnies de téléphonie mobile utilisent des systèmes de détection des anomalies (ADS) dans leurs réseaux cellulaires pour identifier et signaler tout dysfonctionnement. Avec l'expansion et la complexité croissante des réseaux mobiles, les ADS deviennent plus vulnérables aux pannes et dépendent davantage des ressources humaines, ce qui peut conduire à une gestion inefficace du réseau et à une diminution de la qualité de l'expérience (QoE) des utilisateurs. La surveillance continue du système de contrôle du réseau est donc cruciale pour faciliter le dépannage. Notre objectif est d'assister les administrateurs réseau dans l'investigation des pannes, étant donné la complexité du réseau et du système de surveillance. Nous visons à détecter les problèmes au sein du système de contrôle des réseaux 4G.

III.1.2 Objective :

Dans ce projet, nous visons à développer une solution de détection d'anomalies capable d'identifier les problèmes dans les systèmes de surveillance des réseaux mobiles. LTE_TL_NET a pour objectif de identifier les anomalies de manière périodique et en temps réel. Ces anomalies peuvent provenir de configurations incorrectes d'appareils, de matériel défectueux entraînant une perte de trafic, ou d'événements inhabituels tels qu'une augmentation du trafic due à un grand événement sportif.

Les exigences de la solution sont multiples. Tout d'abord, elle doit être pratique, capable de détecter les anomalies dans les mesures des réseaux mobiles.

Deuxièmement, la solution doit identifier les anomalies en fonction de modèles appris.

La solution doit également être proactive dans la détection des anomalies et fonctionner sans surveillance, Son installation doit être simple, avec un nombre limité de paramètres facilement compréhensibles et modifiables par l'utilisateur final. Surtout, la solution doit avoir un faible taux d'erreur, en détectant efficacement les anomalies majeures avec peu de faux positifs. Enfin, elle doit avoir des besoins de calcul minimaux, avec une phase d'apprentissage de faible complexité et une détection des anomalies ayant une complexité temporelle constante pour assurer la meilleure réactivité possible.

L'objectif de ce travail est d'aidée l'équipe d'optimisation du réseau a analyser des traces d'activité passée, qui seront utilisées pour former un système ML capable de classer des échantillons d' activité actuelle comme:

- **0 (normal):** l'activité actuelle correspond au comportement normal de n'importe quelle journée de travail et. Par conséquent, il n'est pas nécessaire de reconfigurer ou de redistribuer les ressources.
- **1 (inhabituel) :** l'activité actuelle diffère légèrement du comportement habituellement observé pour cette période de la journée (par exemple, en raison d'une grève, d'un démonstration, de l'événement sportif, etc.), ce qui devrait déclencher une reconfiguration de la station de base

III.1.3- Exigences et performance:

Pour garantir une performance élevée du réseau 4G, le système de surveillance doit être efficace. L'efficacité se traduit par des exigences différentes. Premièrement, le système de surveillance devrait être adapté à la croissance du trafic et à l'expansion des réseaux cellulaires . Deuxièmement, le système de surveillance devrait être flexible pour superviser les équipements de réseau multi-vendants et hétérogènes. Troisièmement, le système de surveillance doit être suffisamment réactif pour détecter les problèmes et déclencher des opérations d'atténuation en temps réel afin de limiter les temps d'arrêt. En outre, il devrait effectuer une analyse approfondie du réseau et aller à de fins niveaux de granularité pour trouver des problèmes cachés. Quatrièmement, le système de surveillance devrait être autonome dans une certaine mesure pour être réactif et réduire les efforts humains nécessaires.

Les tâches répétitives devraient être automatisées. Les tâches plus avancées peuvent être partiellement automatisées par l'utilisation de ML.

Les réglages du système de surveillance devraient être simples. En outre, il doit être conforme aux normes de télécommunications et au marché.

Le système de surveillance doit respecter les normes en assurant le QoS requis. Il doit

également répondre aux besoins évoqués (p. ex. intégrer de nouvelles fonctions pour surveiller les nouveaux services). En outre, il doit être tolérant aux défauts et facile à résoudre.

Enfin, le système de surveillance doit être rentable. Comme le trafic réseau est énorme, l'analyse mise en œuvre dans le système de surveillance doit être optimisée pour réduire les besoins en informatique. Le système de surveillance devrait également stocker uniquement les données nécessaires et pendant une période limitée.

III.2-Collecte des données et base de données :

III.2.1- Types de données utilisée (Dataset) :

L'ensemble de données a été obtenu à partir d'un déploiement LTE réel. Pendant deux semaines, différentes mesures ont été recueillies à partir d'un ensemble de 10 stations de base, chacune ayant un nombre différent de cellules, toutes les 15 minutes. L'ensemble de données est fourni sous la forme d'un fichier csv, où chaque ligne correspond à un échantillon obtenu à partir d'une cellule particulière à un moment donné. Chaque exemple de données contient les caractéristiques suivantes[45] :

- **Heure :** heure du jour (dans le format hh:mm) où l'échantillon a été généré.

- **CellName1:** chaîne de texte utilisée pour identifier uniquement la cellule qui a généré l'échantillon actuel.
  CellName est dans la forme xαLTE, où x identifie la station de base, et α la cellule à l'intérieur de cette station (see the example in the right figure).

- **PRBUsageUL et PR BUsageDL:** niveau d'utilisation des ressources dans cette cellule mesuré comme la portion de blocs radio physiques (PRB) qui étaient en usage (%) au cours des 15 minutes précédentes. Uplink (UL) et downlink (DL) sont mesurés séparément.

- **meanThrDL et meanTrUL :** trafic moyen transporté (en Mbps) au cours des 15 dernières minutes. Uplink (UL) et downlink (DL) sont mesurés séparément.

- **MaxThrDL et maxThrUL :** trafic maximal transporté (en Mbps) mesuré au cours des 15 dernières minutes. Uplink (UL) et downlink (DL) sont mesurés séparément.

- **meanUEDL et meanUEUL :** nombre moyen d'appareils utilisateurs (UE) actifs simultanément au cours des 15 dernières minutes. Uplink (UL) et downlink (DL) sont mesurés séparément.

- **maxUEDL et maxUEUL :** nombre maximum d'appareils utilisateur (UE) qui ont été actifs simultanément au cours des 15 dernières minutes. Uplink (UL) et downlink (DL) sont mesurés séparément.

- **maxUE_UL+DL :** nombre maximum d'appareils utilisateur (UE) qui ont été actifs simultanément au cours des 15 dernières minutes, indépendamment des UL et DL.

- **Inhabituel :** étiquettes pour l'apprentissage supervisé. Une valeur de 0 détermine que l'échantillon correspond à un fonctionnement normal, une valeur de 1 identifie un comportement inhabituel.

III.2.2-Collecte des données :

L'algorithme LTE_TL_NET détecte les anomalies dans un système de surveillance de réseau cellulaire en analysant le trafic généré par le système de contrôle lui-même. Nous présentons le système global dans la figure 09. Chaque entité surveillée génère des records de données d'appel (CDR), envoyés au module de surveillance de l'ADS, ainsi que des rapports de génération d'enregistrements (RGR) destinés au LTE_TL_NET. Les RGR sont des rapports créés à partir des mesures du système de surveillance par LTE_TL_NET. Ils incluent le nombre de CDR, les enregistrements de données TCP (TCPDR), et d'autres métriques pertinentes.

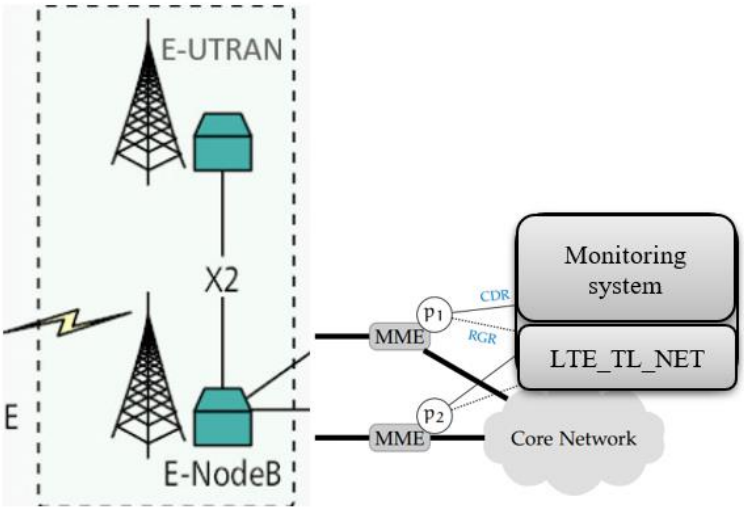


Figure III 1 : Architecture générale de l'acquisition de données

III.2.3-Description de la base de données :

L'ensemble de données a été obtenu à partir d'un déploiement LTE réel[48][49]. Pendant deux semaines, différentes mesures ont été recueillies à partir d'un ensemble de 10 stations de base, chacune ayant un nombre différent de cellules, toutes les 15 minutes.

Le jeu de données LTE est couramment utilisé pour entraîner des algorithmes d'apprentissage automatique et de vision par ordinateur. Il comprend 36 904 traces réparties en deux classes distinctes de la manière suivante :

- 70 % pour l'apprentissage

- 30 % pour les tests

Les deux classes représentent une activité normale (0) et une activité inhabituelle (1).

Dans les systèmes de télécommunications, il est difficile d'obtenir une quantité importante de données étiquetées, car cela nécessite l'intervention d'experts en télécommunications pour classer chaque signal, ce qui est à la fois coûteux et chronophage. L'apprentissage par transfert offre une solution pour surmonter cette difficulté. Cette technique consiste à utiliser un modèle préalablement entraîné sur un ensemble de données volumineux et à appliquer les poids du réseau déterminés dans ce modèle à un problème impliquant un ensemble de données plus restreint. Pour démontrer la robustesse de notre solution, nous proposons d'abord une approche basée sur le deep learning, que nous comparerons ensuite avec la solution finale utilisant l'apprentissage par transfert.

III.3-Expérimentations et discutions :

III.3.1- Solution avec deep learning :

Pour la classification en utilisant réseau neuronal fabriqué (ANN). Nous avons effectué cette implimentation en utilisant Matlab, avec les étapes suivants du programme:

III.3.1.1- processus d'entraînement du réseau de neurones :

Le processus comprend le chargement, la normalisation, la division des données, la définition de l'architecture du réseau, la configuration des options d'entraînement et l'entraînement du modèle comme suit :

a) **Chargement des données :** Les données sont chargées à partir d'un fichier CSV.

b) **Prétraitement des données :** Les caractéristiques sont normalisées à l'aide de la fonction normalize, pour ajuster les valeurs des caractéristiques et les mettre sur une échelle commune, ce qui améliore les performances des algorithmes d'apprentissage automatique. Cela assure une contribution égale de chaque caractéristique, accélère la convergence des algorithmes d'optimisation et améliore la précision des méthodes basées sur la distance.

La normalisation est essentielle pour une analyse de données cohérente et efficace.

c) **Division des données :** Les données sont divisées en ensembles d'apprentissage (XTrain et YTrain) et de test (XTest et YTest), avec 30 % des données pour le test et 70 % pour l'apprentissage. Les variables XTrain et YTrain contiennent les données et étiquettes d'apprentissage, tandis que XTest et YTest contiennent les données et étiquettes de test.

d) **Définition de l'architecture du réseau de neurones :** L'architecture définie consiste en une couche d'entrée qui prend les caractéristiques des données, suivie de deux couches entièrement connectées de 50 neurones chacune, chaque couche étant suivie d'une couche ReLU pour introduire la non-linéarité. Ensuite, une couche entièrement connectée avec 2 neurones prépare les données pour la classification en deux classes, suivie d'une couche softmax pour convertir les scores en probabilités, et enfin, une couche de classification pour évaluer les prédictions (voir Figure 1).

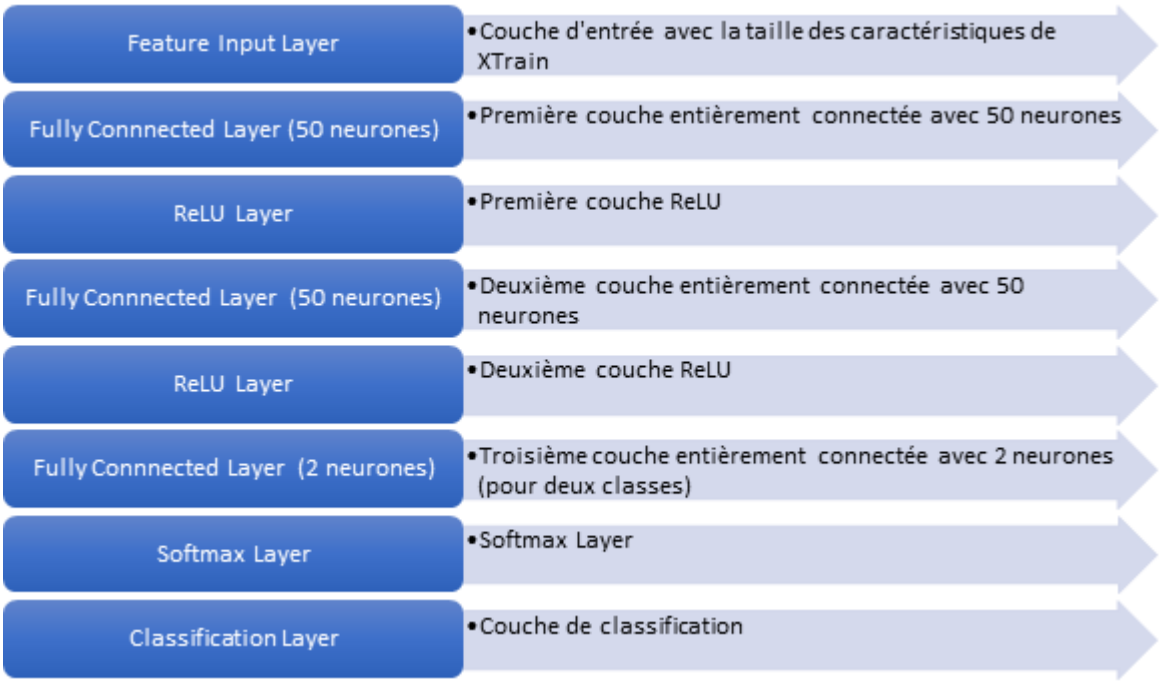


Figure III 2 : architecture du réseau de neurones DL.

e) **Définition des options d'entraînement** : Le tableau suivant présente les différents paramètres utilisés pour configurer l'entraînement du réseau de neurones :

Tableau III.1: Paramètres et Valeurs pour l'Optimisation du Modèle de Classification.

Paramètre	Valeur	Description
Algorithme d'optimisation	Adam	Utilise l'algorithme Adam pour l'optimisation des poids.
MaxEpochs	100	Nombre maximal d'époques (passages complets sur les données d'entraînement).
MiniBatchSize	150	Taille des mini-lots (sous-ensembles des données d'entraînement utilisés à chaque itération).
InitialLearnRate	0.001	Taux d'apprentissage initial (contrôle la taille des ajustements des poids).
Shuffle	every-epoch	Mélange les données d'entraînement à chaque époque pour améliorer la généralisation.

Ces options configurent l'entraînement du réseau de neurones en utilisant l'algorithme Adam sur une durée de 100 époques, avec des mini-lots de 150 échantillons et un taux

d'apprentissage initial de 0.001.

Les données sont mélangées à chaque époque pour améliorer la généralisation, et les progrès de l'entraînement sont visualisés en temps réel grâce à des graphiques. Ces paramètres sont essentiels pour optimiser le processus d'apprentissage et surveiller les performances du réseau pendant l'entraînement.

f) Entraînement du réseau de neurones : Le réseau de neurones est entraîné sur les données d'apprentissage (XTrain et YTrain) à l'aide de la fonction trainNetwork.

III.3.1.2- Évaluation du réseau de neurones :

Le réseau de neurones entraîné est évalué sur les données de test (XTest) et l'exactitude du modèle est calculée.

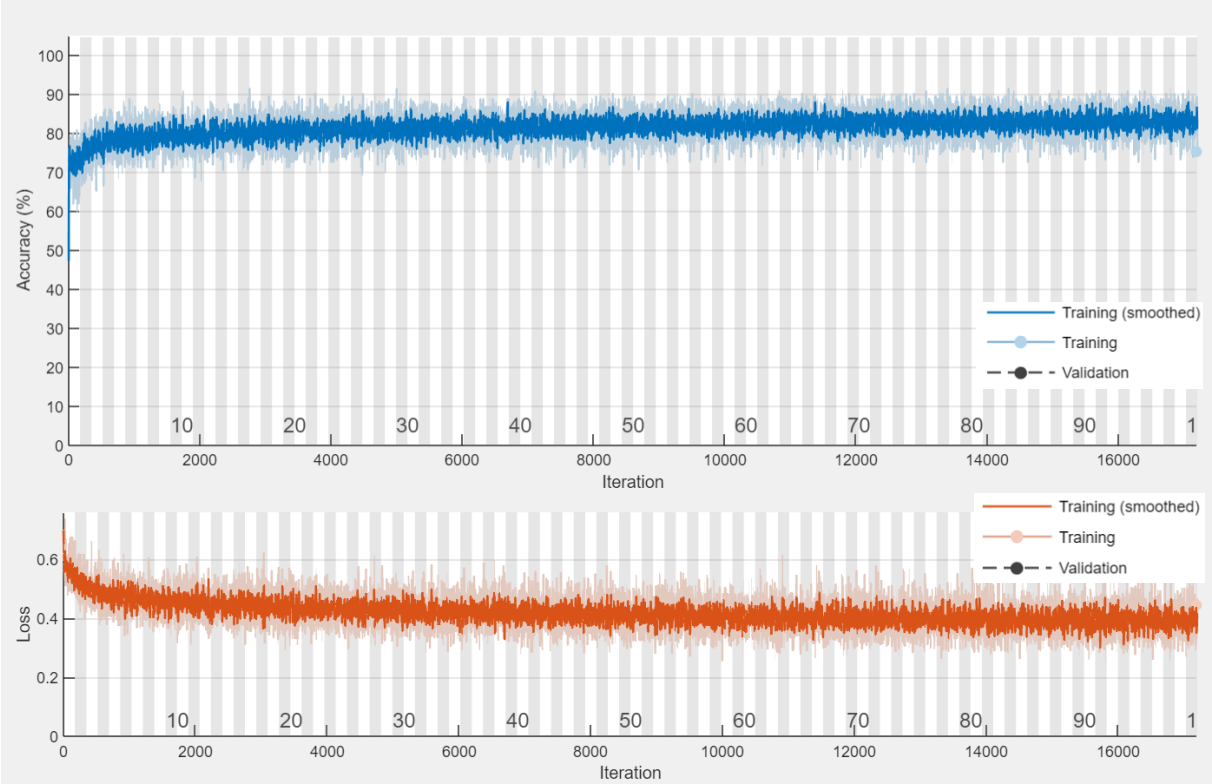


Figure III.3: Évolution de la précision d'entraînement et de validation au cours des itérations.

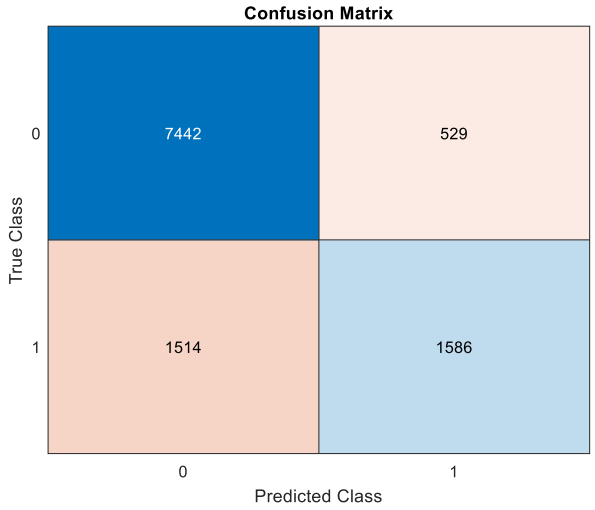


Figure III.4: matrice de confusion (DL).

III.3.1.3-la matrice de confusion :

En étudiant les résultats de la matrice de confusion obtenue on constate :

- **TP (Vrais Positifs) :** Il y a eu 7442 prédictions positives correctes. Cela signifie que le modèle a correctement identifié 7442 cas comme positifs parmi ceux qui étaient réellement positifs.
- **TN (Vrais Négatifs) :** Il y a eu 1586 prédictions négatives correctes. Cela signifie que le modèle a correctement identifié 1586 cas comme négatifs parmi ceux qui étaient réellement négatifs.
- **FN (Faux Négatifs) :** Il y a eu 1514 prédictions négatives incorrectes. Cela signifie que le modèle a manqué 1514 cas qui étaient réellement positifs et les a classés à tort comme négatifs.
- **FP (Faux Positifs) :** Il y a eu 529 prédictions positives incorrectes. Cela signifie que le modèle a classé à tort 529 cas qui étaient réellement négatifs comme positifs.

bien que le modèle ait une capacité moyenne à identifier les vrais positifs et négatifs, il doit nécessiter des ajustements pour réduire le nombre de faux négatifs et faux positifs, afin d'améliorer la précision globale.

III.3.1.4-Métriques d'évaluation du DL:

Ce model vise à fournir un modèle de classification avec les résultats suivantes :

1. **Taux de Vrais Positifs (TVP)** : Le modèle a correctement identifié 83,1 % des cas positifs.
2. **Taux de Faux Positifs (TFP)** : Le modèle a classé à tort 25,01 % des cas négatifs comme positifs.
3. **Taux de Vrais Négatifs (TVN)** : Le modèle a correctement identifié 74,99 % des cas négatifs.
4. **Taux de Faux Négatifs (TFN)** : Le modèle a classé à tort 16,9 % des cas positifs comme négatifs.
5. **Score F1** : Un score F1 de 87,93 indique une bonne performance globale.
6. **Précision de Test** : Le modèle a atteint une précision de 81,73 %, ce qui signifie qu'il a correctement classé 81,73 % des instances dans l'ensemble de test.

Dans l'ensemble, le modèle semble avoir de performances moyennes, surtout compte tenu du score F1, qui indique un équilibre entre la précision et le rappel.

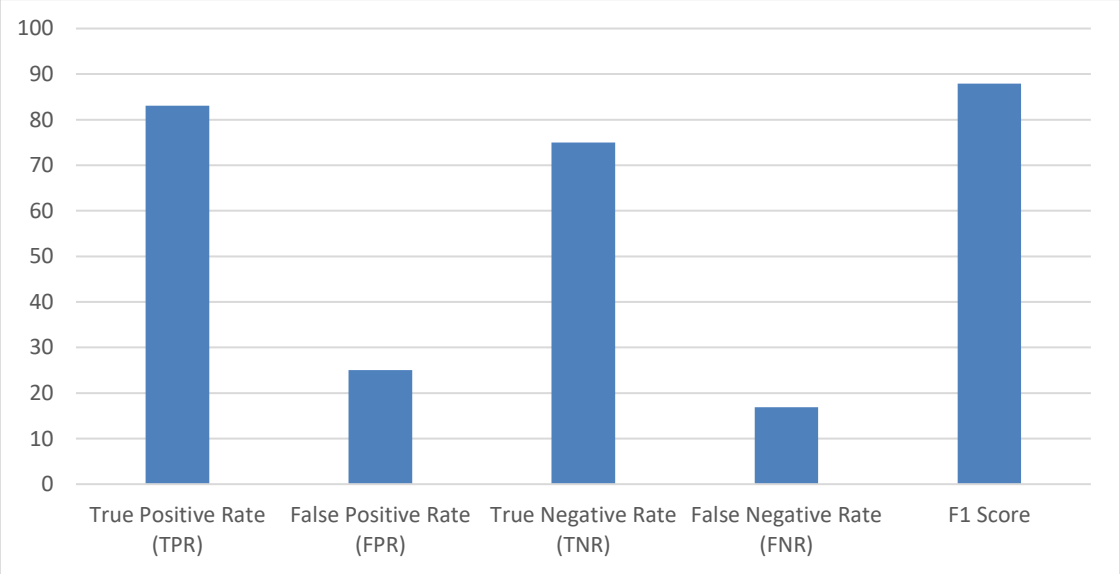


Figure III.5: **Mesures de Performance d'un Modèle de Classification.**

III.3.2-Solution avancée avec Deep Learning (avec la moyenne) :

Nous avons utilisé MATLAB pour concevoir un programme visant à entraîner et évaluer un réseau neuronal destiné à classifier des données en se basant sur la moyenne des caractéristiques partagées par chaque groupe de données.

- **Calcul de la moyenne par groupe :**

La moyenne est calculée pour les données regroupées selon trois colonnes spécifiques: "Time", "CellName" et "Unusual". Cette opération est réalisée pour le calcule la moyenne des données pour chaque groupe distinct défini par ces colonnes. convertissant ainsi la structure de tableau contenant les moyennes en un fichier CSV.

Cette étape est essentielle pour agréger et résumer de grandes quantités de données, ce qui facilite leur analyse et leur présentation dans divers domaines.

- **processus d'entraînement du réseau de neurones :**

Le processus d'entraînement comprend les mêmes étapes que celles décrites dans la section précédente, à savoir le chargement des données, leur normalisation, leur division, la définition de l'architecture du réseau, la configuration des options d'entraînement, et finalement l'entraînement du modèle.

III.3.2.1- Évaluation du réseau de neurones (avec la moyenne):

Avec l'utilisation de la moyenne dans le processus de classification, le taux de précision lors du test atteint 99,89 %. Cela démontre l'efficacité de l'approche utilisée, où les données sont regroupées selon certaines caractéristiques clés avant d'être classifiées. Cette conclusion est appuyée par les résultats visuels présentés dans le graphique suivants .

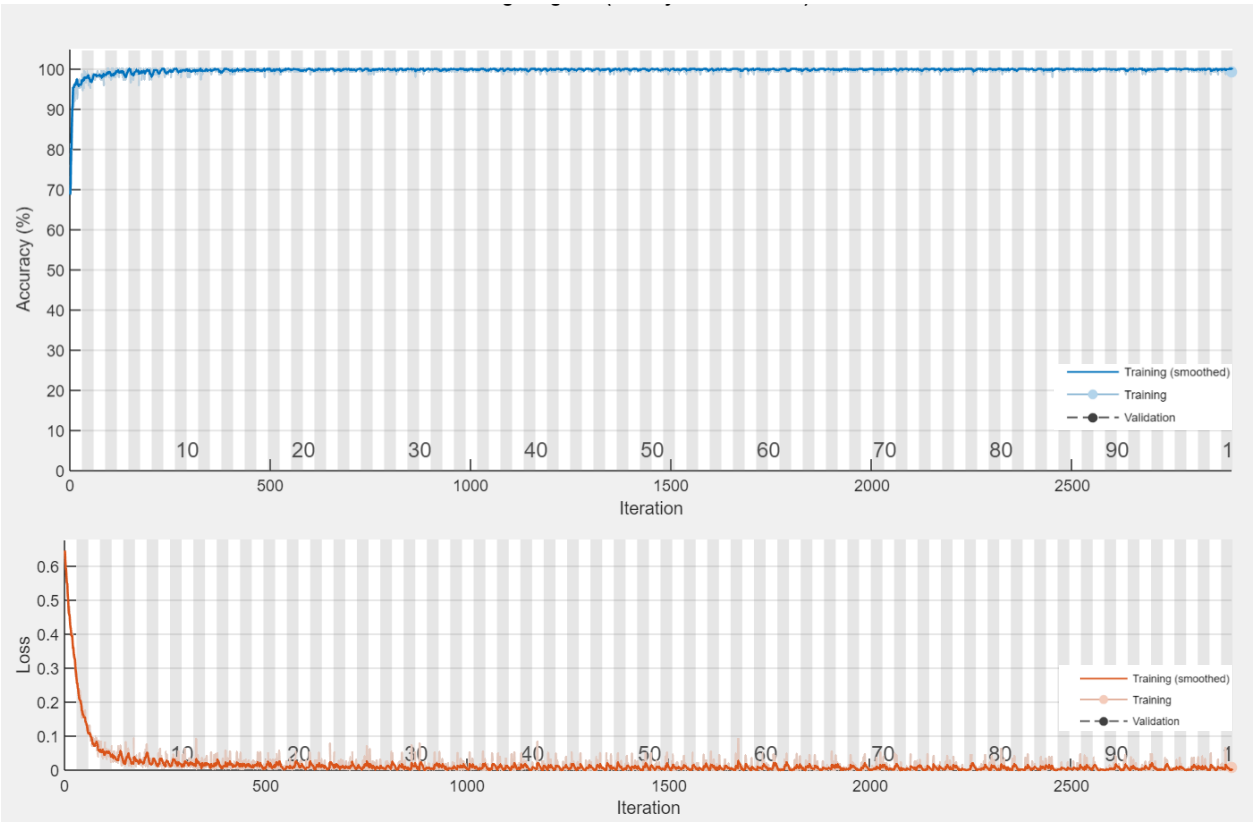


Figure III.6: Évolution de la précision d'entraînement et de validation au cours des itérations(avec la moyenne).

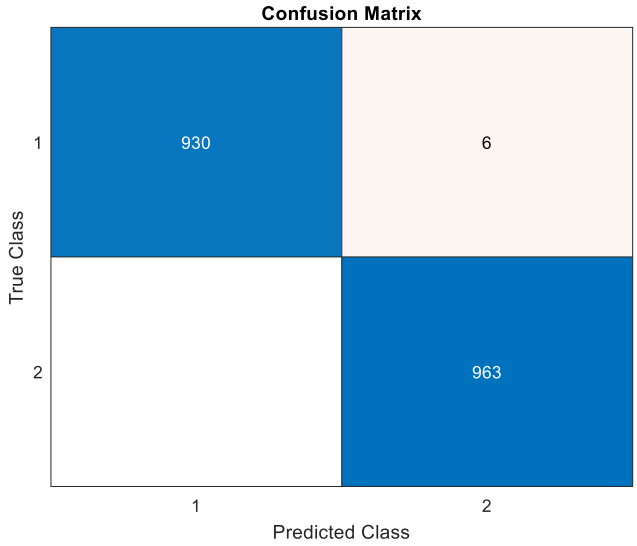


Figure III.7: Matrice de confusion (DL avec la moyenne).

III.3.2.2-Matrice de confusion :

En étudiant les résultats de la matrice de confusion obtenue on constate:

- **TP (Vrais Positifs) :** 930 Cela signifie que le modèle a correctement identifié 930 cas comme positifs parmi ceux qui étaient réellement positifs.
- **TN (Vrais Négatifs) :** 963 Cela signifie que le modèle a correctement identifié 963 cas comme négatifs parmi ceux qui étaient réellement négatifs.
- **FN (Faux Négatifs) :** 0 Cela signifie que le modèle a manqué 0 cas qui étaient réellement positifs et les a classés à tort comme négatifs.
- **FP (Faux Positifs) :** 6 Cela signifie que le modèle a classé à tort 6 cas qui étaient réellement négatifs comme positifs.

Le modèle présente une excellente capacité à identifier correctement les cas positifs (haut rappel), mais il a une faible précision, ce qui indique un nombre élevé de faux positifs. La proportion de vraies prédictions positives parmi toutes les prédictions positives est relativement faible (précision de 49.1%). Le nombre de faux négatifs est très faible, ce qui signifie que le modèle rate rarement les cas positifs.

Pour améliorer encore les performances du modèle, il serait bénéfique d'ajuster les seuils de décision pour réduire le nombre de faux positifs, ou d'utiliser des techniques de rééchantillonnage pour équilibrer les classes dans les données d'entraînement.

III.3.2.3-Métriques d'évaluation du DL:

Ce modèle vise à fournir un modèle de classification avec les résultats suivants :

1. **Taux de Vrais Positifs (TVP) :** Le modèle a correctement identifié 100 % des cas positifs.
2. **Taux de Faux Positifs (TFP) :** Le modèle a classé à tort 0,62 % des cas négatifs comme positifs.
3. **Taux de Vrais Négatifs (TVN) :**Le modèle a correctement identifié 99,38 % des cas négatifs.
4. **Taux de Faux Négatifs (TFN) :** Le modèle a classé à tort 0 % des cas positifs comme négatifs.
5. **Score F1 :** Un score F1 de 99,68 indique une excellente performance globale.

6. Précision de Test : La précision n'est pas explicitement fournie dans les nouveaux paramètres, mais étant donné les taux élevés de vrais positifs et vrais négatifs, on peut en déduire qu'elle serait également très élevée.

Dans l'ensemble, le modèle semble avoir des performances exceptionnelles, surtout compte tenu du score F1, qui indique un excellent équilibre entre la précision et le rappel. Ces résultats montrent que le modèle est capable de classer presque parfaitement les instances positives et négatives, avec un taux de faux positifs et de faux négatifs presque négligeable.

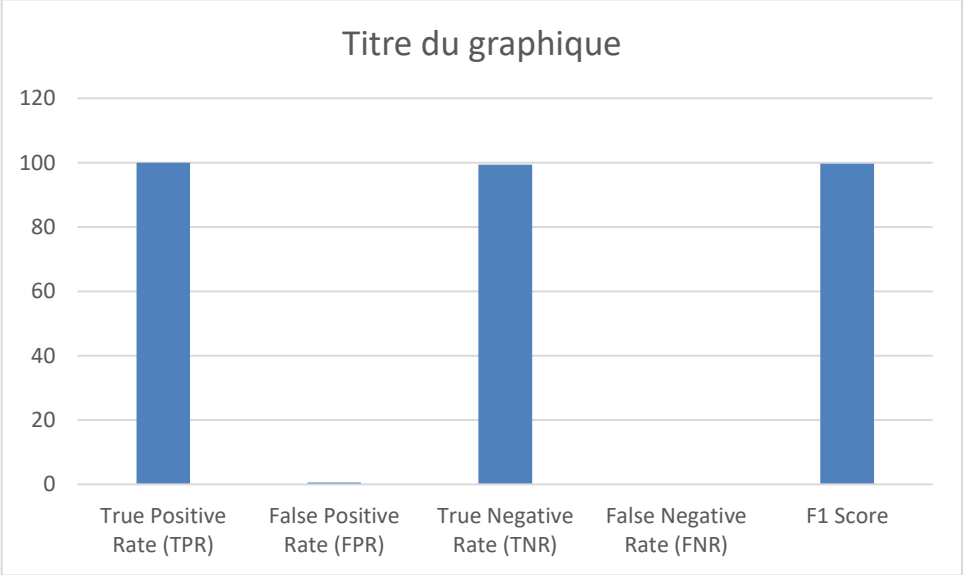


Figure III.8: **Mesures de Performance d'un Modèle de Classification (avec la moyenne).**

III.3.3-Modèle proposé pour le Transfert Learning :

Nous utiliserons l'apprentissage par transfert au moyen du modèle préformé squeezent. Nous allons prendre le squeeznet et enlever le dernier niveau de classification ; puis nous ajouterons un niveau de classification avec deux classes .

Nous formons notre réseau au cours de 06 époque et nous obtenons l'exactitude et l'erreur sur les données d'apprentissage et les données de test. L'exactitude des données d'apprentissage a atteint 97.21%, tandis que celle des données de test a atteint 94, 23%.

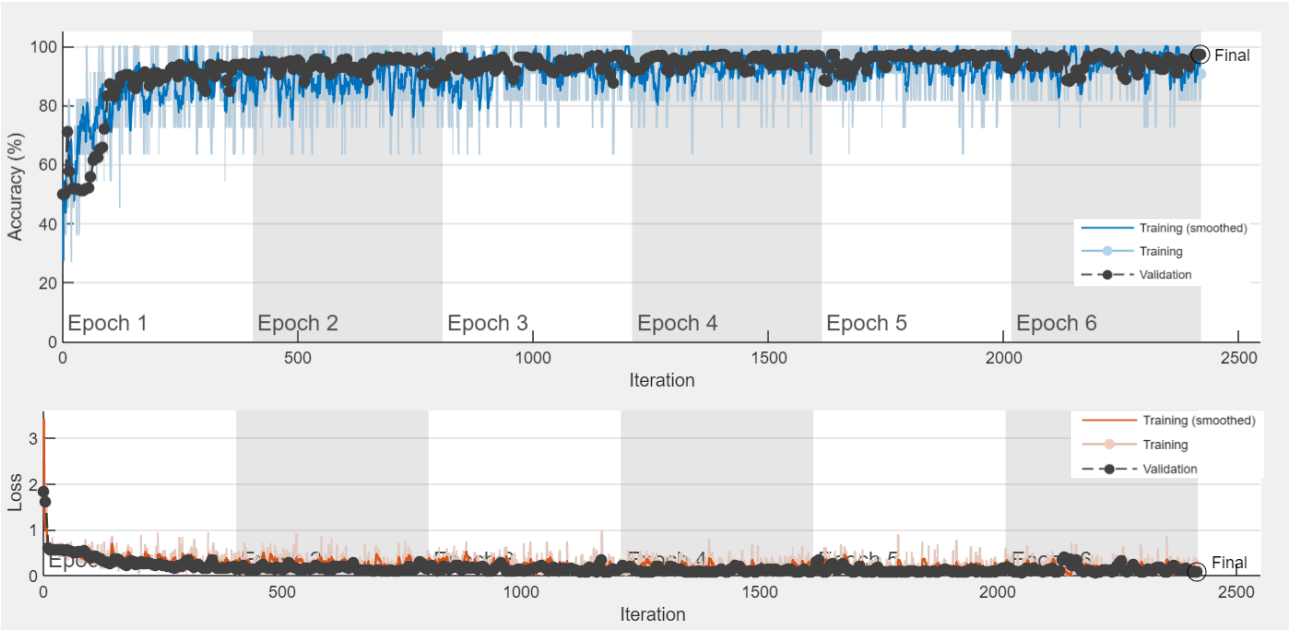


Figure III.9: Évolution de la précision d'entraînement et de validation au cours des itérations.

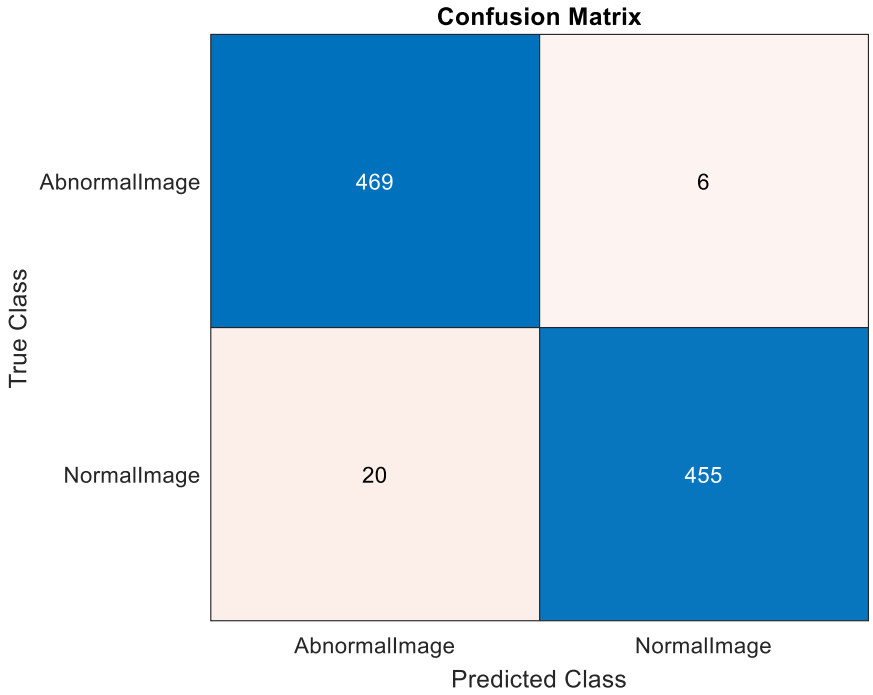


Figure III.10: Matrice de confusion (TL).

III.3.3.1-Matrice de confusion :

En étudiant les résultats de la matrice de confusion obtenue, on constate :

- **TP (Vrais Positifs) :** 469 Cela signifie que le modèle a correctement identifié 469 cas comme positifs (Normal Image) parmi ceux qui étaient réellement positifs.
- **TN (Vrais Négatifs)** : 455 Cela signifie que le modèle a correctement identifié 455 cas comme négatifs (Abnormal Image) parmi ceux qui étaient réellement négatifs.
- **FN (Faux Négatifs) :** 20 Cela signifie que le modèle a manqué 20 cas qui étaient réellement positifs et les a classés à tort comme négatifs.
- **FP (Faux Positifs)** : 6 Cela signifie que le modèle a classé à tort 6 cas qui étaient réellement négatifs comme positifs.

Le modèle présente une excellente capacité à identifier correctement les cas positifs (haut rappel) et les cas négatifs (haut taux de vrais négatifs). La précision est également très élevée, ce qui signifie que le nombre de faux positifs est faible. Le nombre de faux négatifs est très faible, ce qui indique que le modèle rate rarement les cas positifs.

Pour améliorer encore les performances du modèle, il serait bénéfique de continuer à affiner les seuils de décision et de maintenir un bon équilibre dans les données d'entraînement pour s'assurer que les classes restent bien représentées.

III.3.3.2-Métriques d'évaluation du TL:

Ce modèle vise à fournir un modèle de classification avec les résultats suivants :

1. **Taux de Vrais Positifs (TVP) :** Le modèle a correctement identifié 96 % des cas positifs.
2. **Taux de Faux Positifs (TFP) :** Le modèle a classé à tort 1 % des cas négatifs comme positifs.
3. **Taux de Vrais Négatifs (TVN) :** Le modèle a correctement identifié 99 % des cas négatifs.
4. **Taux de Faux Négatifs (TFN) :** Le modèle a classé à tort 4 % des cas positifs comme négatifs.
5. **Score F1 :** Un score F1 de 97 indique une excellente performance globale.

6. **Précision de Test :** Le modèle a atteint une précision de 99 %, ce qui signifie qu'il a correctement classé 99 % des instances dans l'ensemble de test.

Dans l'ensemble, le modèle semble avoir des performances excellentes, surtout compte tenu du score F1, qui indique un très bon équilibre entre la précision et le rappel.

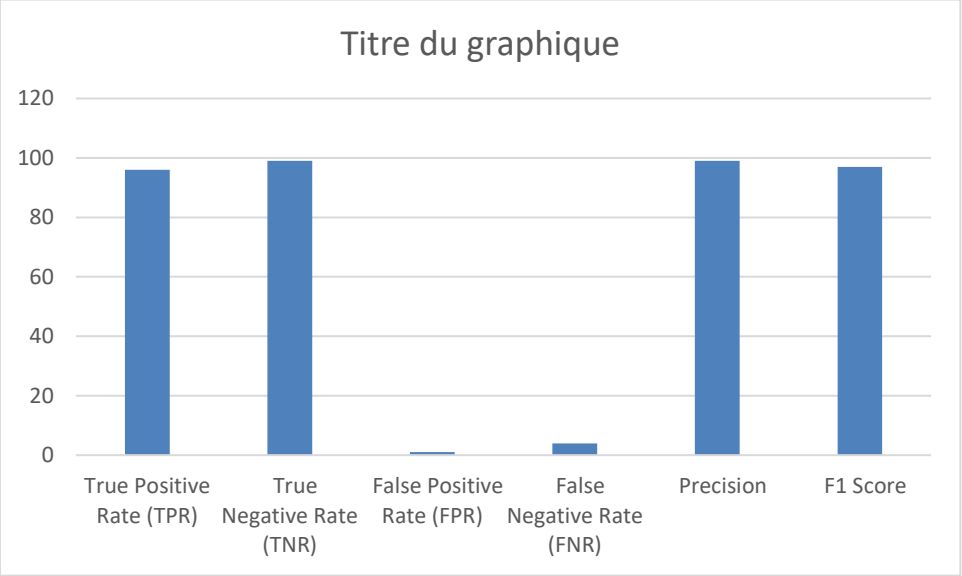


Figure III.11: **Mesures de Performance d'un Modèle de Classification.**

III.4-Comparaison des résultats :

Trois expériences ont été réalisées pour la comparaison entre l'apprentissage traditionnel et l'apprentissage par transfert, la première sur la base du DL, la deuxième sur le DL avec la moyenne et la troisième sur l'apprentissage par transfert. Dans les trois cas on voit que l'apprentissage par transfert diminué un peut l'exactitude, par exemple la première expérimentation sur la base du DL a obtenu une exactitude de 87.93% sur les données de test cependant lorsqu'on a utilisé le le DL avec la moyenne cette exactitude augmante à 99.68 %, pour l'apprentissage par transfert en utilisant le rseaux squeeznet avec transfert cette exactitude est diminuée à 97.21%. Les paramètres obtenus avec le transfert sont légèrement moins élevés que ceux sans transfert, mais deux choses très importantes ont été gagnées avec le transfert.

III.4.1-Résultats détaillés :

- **Taux de vrais positifs (TPR) :**
  - **DL classique** : 83.1%
  - **DL avec la moyenne** : 100%

- **Tlsqueez** : 96%

On observe que l'apprentissage par transfert (Tlsqueez) et le DL avec la moyenne atteignent des taux de vrais positifs plus élevés que le DL classique. Le DL avec la moyenne obtient le meilleur résultat avec 100%, tandis que Tlsqueez atteint 96%, surpassant largement le DL classique à 83.1%.

- **Taux de faux positifs (FPR) :**
  - **DL classique** : 25.01%
  - **DL avec la moyenne** : 0.62%
  - **Tlsqueez** : 1%

Le DL avec la moyenne et Tlsqueez montrent une réduction significative des taux de faux positifs comparé au DL classique. Tlsqueez atteint 1%, ce qui est très proche du résultat de 0.62% du DL avec la moyenne, et bien inférieur aux 25.01% du DL classique.

- **Taux de vrais négatifs (TNR) :**
  - **DL classique** : 74.99%
  - **DL avec la moyenne** : 99.38%
  - **Tlsqueez** : 99%

Les résultats montrent que le DL avec la moyenne et Tlsqueez atteignent des taux de vrais négatifs très élevés, respectivement 99.38% et 99%, comparé au DL classique à 74.99%.

- **Taux de faux négatifs (FNR) :**
  - **DL classique** : 16.9%
  - **DL avec la moyenne** : 0%
  - **Tlsqueez** : 4%

Le DL avec la moyenne élimine complètement les faux négatifs (0%), suivi par Tlsqueez avec un faible taux de 4%, tandis que le DL classique présente un taux de faux négatifs de 16.9%.

- **F1 Score :**
  - **DL classique** : 87.93
  - **DL avec la moyenne** : 99.68
  - **Tlsqueez** : 97

Le F1 score est une mesure de la précision globale et du rappel. Le DL avec la moyenne obtient le meilleur score de 99.68, suivi par Tlsqueez avec 97, surpassant le DL classique qui obtient 87.93.

Les résultats montrent que l'apprentissage par transfert (Tlsqueez) et le DL avec la moyenne surpassent le DL classique dans presque tous les aspects mesurés. Bien que l'apprentissage par transfert ait légèrement diminué la précision par rapport au DL avec la moyenne, il reste très performant et offre des avantages significatifs :

1. **Réduction des faux positifs** : Tlsqueez atteint un taux de faux positifs très bas (1%) comparé au DL classique (25.01%).
2. **Performance équilibrée** : Tlsqueez offre un bon équilibre entre la détection des vrais positifs et la minimisation des faux négatifs, avec un F1 score élevé de 97.

En conclusion, bien que les paramètres obtenus avec le transfert soient légèrement moins élevés que ceux sans transfert, deux avantages importants sont obtenus avec le transfert : une réduction significative des faux positifs et une performance équilibrée.

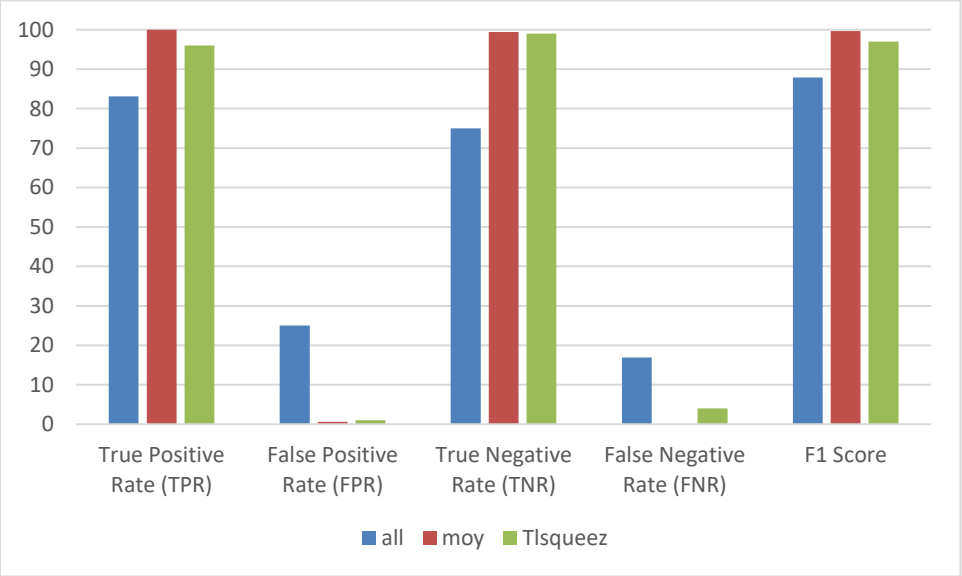


Figure III. 12 : Comparaison des performances.

III.5-Comparaison avec des travaux antérieurs :

III.5.1-Travaux sur la détection d'anomalies dans les réseaux LTE :

Plusieurs études ont été menées pour la détection d'anomalies dans les réseaux LTE en utilisant des méthodes d'apprentissage automatique. Stan a décrit une méthodologie visant à entraîner un système ML à partir de traces d'activité passée, collectées sur deux semaines à partir de 10 stations de base, pour classer l'activité actuelle comme normale ou inhabituelle avec une précision de 90% à 94%. Gerard Castell et Sergio Gimenez ont exploré des solutions ML pour détecter les anomalies dans les réseaux cellulaires 4G, obtenant une précision remarquable de 99.83%. Leur approche utilise probablement des techniques d'apprentissage supervisé ou non supervisé, ainsi que des réseaux de neurones et des arbres de décision pour analyser les données des stations de base. Brayden Chang et Edwin Ang ont utilisé des arbres de décision et XGBoost pour prédire le comportement normal et anormal dans les réseaux LTE, atteignant une précision de 96% à 98%. Leur étude met en lumière l'importance des ajustements dynamiques basés sur les états opérationnels identifiés par ces modèles.[52][53][54]

III.5.2-comparison des travaux sur la détection d'anomalies :

La figure suivante représente les précisions moyennes obtenues par différentes méthodes d'évaluation. Stan a atteint une précision de 92%, tandis que Gerard Castell a obtenu le score le plus élevé avec 99.83%. Brayden a également montré de solides performances avec une précision de 97%. Enfin, notre propre solution a réalisé un résultat prometteur de 99.68%. Ces chiffres illustrent clairement les différentes capacités des méthodes évaluées, mettant en évidence la robustesse exceptionnelle de Gerard Castell et notre solution par rapport à Stan et Brayden.

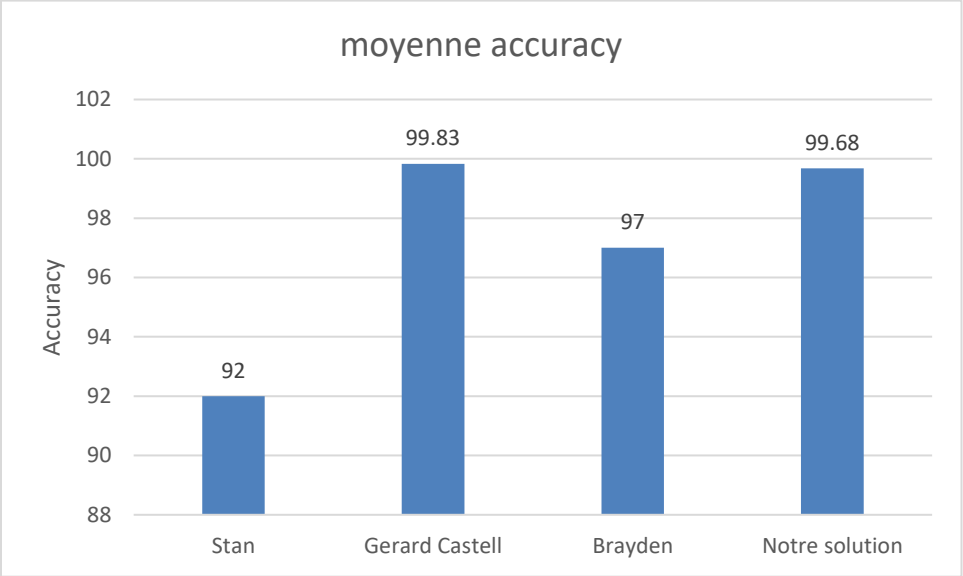


Figure III.13 : comparaison des travaux sur la détection d'anomalies

III.6-Conclusion :

Dans ce chapitre, nous avons comparé l'apprentissage classique à l'apprentissage par transfert. La première approche utilise des ensembles de données standard 4G, tandis que la seconde utilise des moyennes de données similaires provenant de la même base de données. Nous avons observé que l'apprentissage par transfert diminue légèrement les performances ; cependant, notre objectif était d'exploiter un modèle d'apprentissage profond pré-entraîné et de l'appliquer à un modèle cible. De manière significative, l'apprentissage par transfert réduit considérablement la complexité, ce qui est particulièrement bénéfique pour traiter le problème bien connu de la rareté des données, surtout dans le domaine des données mobiles.

CONCLUSION GENERALE

Conclusion générale :

Depuis des décennies, l'intelligence artificielle a permis le développement d'applications opérationnelles dans de nombreux domaines, tels que le diagnostic et l'aide à la décision, grâce à des systèmes basés sur la connaissance ou à des réseaux neuronaux.

L'émergence des outils d'intelligence artificielle entraîne une nouvelle organisation du travail dans la reconnaissance des signaux. L'IA facilite et améliore considérablement les pratiques d'évaluation, permettant aux utilisateurs de consacrer plus de temps à d'autres tâches. Il est également important de considérer l'apparition de nouvelles professions, telles que la science des données, qui assurent le bon fonctionnement des outils d'IA. Ces professions multidimensionnelles favorisent la communication entre les concepteurs et les scientifiques des données pour identifier les besoins et améliorer le développement des outils d'IA.

En parallèle, l'intelligence artificielle et ses branches, telles que le machine learning, le deep learning et le transfer learning, jouent un rôle essentiel dans le développement technologique. L'IA offre le cadre théorique tandis que le ML et le DL apportent des solutions pratiques en permettant aux machines d'apprendre à partir des données. Le transfer learning améliore ce processus en transférant des connaissances entre différentes tâches, augmentant ainsi l'efficacité. La combinaison de ces technologies stimule des innovations qui transforment divers secteurs, de la santé à l'industrie. En comprenant les liens entre ces domaines, nous pouvons mieux prévoir leur potentiel et leur impact sur la transformation de notre monde.

Dans ce travail, nous avons présenté une solution pour aider les opérateurs mobiles à diagnostiquer leurs réseaux mobiles 4G et à détecter des anomalies ou des charges de trafic inhabituelles, en utilisant tout d'abord un réseau de deep learning simple, avant d'opter pour le transfer learning. Cette solution a donné des performances acceptables, de l'ordre de 97 % d'accuracy.

Pour les travaux futurs, nous proposons de développer un système de détection d'anomalies capable d'identifier les problèmes survenant dans un système de supervision en temps réel et de manière dynamique dans un réseau mobile réel.

Références :

[1] Ajay R Mishra. Fundamentals of Network Planning and Optimisation 2G/3G/4G: Evolution to 5G. John Wiley & Sons,
2018.
[2] Ajay R Mishra. Advanced cellular network planning and optimisation: 2G/2.5 G/3G... evolution to 4G. John Wiley &
Sons, 2007.
[3] Poojitha Pattem. Research on detection and prevention of rogue base stations in the 5g network. 2022.
[4] Vijay Garg. Wireless communications & networking. Elsevier, 2010.
[5] Alexander Kukushkin. Introduction to mobile network engineering: Gsm, 3g-wcdma, lte and the road to 5g. John
Wiley & Sons, 2018.
[6] Sassan Ahmadi. LTE-Advanced: a practical systems approach to understanding 3GPP LTE releases 10 and 11 radio
access technologies. Academic Press, 2013.
[7] Stefania Sesia, Issam Toufik, and Matthew Baker. LTE-the UMTS long term evolution: from theory to practice. John
Wiley & Sons, 2011.
[8] Nadew Sikuwaru Kibret et al. Study of lte and lte-advanced as a low cost backhauling solution for hspa small cells.
2014.
[9] OULDMAAMAR YOUCEF, MOHAMED ABDELLAH SKENDER, L'intelligence Artificielle et son application dans la vidéosurveillance UNIV Yahia farés Médéa , Faculté de Technologie Département de Génie électrique Pour L'Obtention du Diplôme de la licence en Télécommunication, Année 2021/2022.
[10] https://www.college-de-france.fr/sites/default/files/documents/presse/UPL7132967935621487999_Dossier_YLeCun.pdf
[11] https://dspace.univ-guelma.dz/jspui/bitstream/123456789/4220/1/PFE2019%20Diallo%20nene%20adama%20dian%20%28Tchi%20drive2%29%20%281%29.pdf
[12] www.image-net.org consultée le : 12 avril 2019
www.fr.wikiversity.org consultée le : 12 avril 2019
[13] Moualek, D. Y. (2017). Deep Learning pour la classification des images (Thèse de doctorat), Université Abou Bakr Belkaid– Tlemcen.
[14] Y. Bengio, A. Courville, and P. Vincent. Representation learning: A review and new perspectives.IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI),38:1798–1828,2013
[15] Hubara, I., Courbariaux, M., Soudry, D., El-Yaniv, R., & Bengio, Y. (2017). Quantized neural networks: Training neural networks with low precision weights and activations. The Journal of Machine Learning Research, 18(1), 6869-6898.
[16] Van den Oord, A., Dieleman, S., & Schrauwen, B. (2013). Deep content-based music recommendation. In Advances in neural information processing systems (pp. 2643-2651).
[17] Collobert, R., & Weston, J. (2008, July). A unified architecture for natural language processing: Deep neural networks with multitask learning. In Proceedings of the 25th international conference on Machine learning (pp. 160-167).

[18] Matsugu, M., Mori, K., Mitari, Y., & Kaneda, Y. (2003). Subject independent facial expression recognition with robust face detection using a convolutional neural network. Neural Networks, 16(5-6), 555-559.
[19] Mikolov, T., Karafiát, M., Burget, L., Černocký, J., & Khudanpur, S. (2010). Recurrent neural network based language model. In Eleventh annual conference of the international speech communication association.
[20] Liu, S., Yang, N., Li, M., & Zhou, M. (2014, June). A recursive recurrent neural network for statistical machine translation. In Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers) (pp. 1491-1500).
[21] Graves, A., & Jaitly, N. (2014, January). Towards end-to-end speech recognition with recurrent neural networks. In International conference on machine learning (pp. 1764-1772).
[22]] Karpathy, A., & Fei-Fei, L. (2015). Deep visual-semantic alignments for generating image descriptions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 3128-3137).
[23] Ng, A. Y., & Jordan, M. I. (2002). On discriminative vs. generative classifiers: A comparison of logistic regression and naive bayes. In Advances in neural information processing systems (pp. 841-848).
[24] Ackley, D. H., Hinton, G. E., & Sejnowski, T. J. (1985). A learning algorithm for Boltzmann machines. Cognitive science, 9(1), 147-169.
[25] Salakhutdinov, R., Mnih, A., & Hinton, G. (2007, June). Restricted Boltzmann machines for collaborative filtering. In Proceedings of the 24th international conference on Machine learning (pp. 791-798).
[26] Hinton, G. E. (2012). A practical guide to training restricted Boltzmann machines. In Neural networks: Tricks of the trade (pp. 599-619). Springer, Berlin, Heidelberg.
[27] Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. Neural computation, 18(7), 1527-1554.
[28] Salakhutdinov, R., & Hinton, G. (2009, April). Deep boltzmann machines. In Artificial intelligence and statistics (pp. 448-455).
[29] Srivastava, N., & Salakhutdinov, R. R. (2012). Multimodal learning with deep boltzmann machines. In Advances in neural information processing systems (pp. 2222-2230).
[30] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative adversarial nets. In Advances in neural information processing systems (pp. 2672-2680).
[31] Denton, E. L., Chintala, S., & Fergus, R. (2015). Deep generative image models using a laplacian pyramid of adversarial networks. In Advances in neural information processing systems (pp. 1486-1494).
[32] www.fr.wikipedia.org. Consultée le : 05 janvier 2019.
[33] Zhang, R., Zhu, J. Y., Isola, P., Geng, X., Lin, A. S., Yu, T., & Efros, A. A. (2017). Realtime user-guided image colorization with learned deep priors. arXiv preprint arXiv:1705.02999. [55] Owens, A., Isola, P., McDermott, J., Torralba, A., Adelson, E. H., & Freeman, W. T. (2016). Visually indicated sounds. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2405-2413).

[34] Owens, A., Isola, P., McDermott, J., Torralba, A., Adelson, E. H., & Freeman, W. T. (2016). Visually indicated sounds. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2405-2413).
[35] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. arXiv preprint arXiv:1406.1078.

[36] Erhan, D., Szegedy, C., Toshev, A., & Anguelov, D. (2014). Scalable object detection using deep neural networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2147-2154).
[37] Graves, A. (2013). Generating sequences with recurrent neural networks. arXiv preprint arXiv:1308.0850.
[38] Karpathy, A., & Fei-Fei, L. (2015). Deep visual-semantic alignments for generating image descriptions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 3128-3137).
[39] Mnih, V., Kavukcuoglu, K., Silver, D., Graves, A., Antonoglou, I., Wierstra, D., & Riedmiller, M. (2013). Playing atari with deep reinforcement learning. arXiv preprint arXiv:1312.5602.
[40] https://fr.wikipedia.org/wiki/Apprentissage_par_transfert
[41] https://www.ibm.com/topics/transfer-learning
[42] https://stringfixer.com/fr/Inductive_transfer
[43] https://machinelearningmastery.com/transfer-learning-for-deep-learning
[44] https://ledatascientist.com/introduction-au-transfer-learning
[45] https://medium.com/@Stan_DS/anamaly-classification-task-ver1-categorical-refactor-c04c298784f4
[46] R. Froehlich, Knowledge base radio and core network prescriptive root cause analysis, US Patent Application 14/621,101, 2016.
[47] P. Berezi ´nski, B. Jasiul, and M. Szpyrka, “An entropy-based network anomaly detection method,” Entropy, 2015
[48] Josep Vidal. (2020).
[49] https://kaggle.com/competitions/anomaly-detection-in-4g-cellular-networks
[50] Nour-Eddine Joudar, Mohamed Ettaouil, et al. Krr-cnn : kernels redundancy reduction in convolutional neural networks. Neural Computing and Applications, 34(3) :2443–2454, 2022.
[51] meritis.fr.
[52] https://medium.com/@Stan_DS/anamaly-classification-task-ver1-categorical-refactor-c04c298784f4
[53] https://github.com/sergio-gimenez/anomaly-4G-detection/blob/master/MLEARN_Competition_Report.pdf
[54] https://medium.com/d-classified/anomaly-detection-in-lte-networks-with-decision-trees-and-xgboost-435a6b8adb50