

Université MUSTAPHA Stambouli
Mascara



جامعة مصطفى اسطمبولي
معسكر

Faculté des Sciences et de la Technologie
Département de Electrotechnique
Laboratoire LSTE

THESE de DOCTORAT 3^{ème} Cycle

Filière : Télécommunications

Spécialité : Réseaux et Télécommunications

Intitulée

Prédiction de nouvelles solutions pour quantifier les anomalies de langage chez l'enfant autiste, et le localiser intelligemment en cas où il est perdu (ou kidnappé)

Présentée par : M. BOUHAMIDA Habib Allah

Soutenu Le 09/07/2025

Devant le jury :

Président	MAACHOU Abdelkader	MCA	Université M.S - Mascara
Examineur	ZOUGGARET Abdelhak	MCA	Université M.S - Mascara
Examineur	DAHANI Ameer	Pr	Université M.T - Saïda
Examineur	BERBER Mohamed	Pr	Centre universitaire N.B-El-Bayadh
Encadreur	MERABET Boualem	Pr	Centre universitaire S.A - Naâma
Co-Encadreur	MOULAY Mohamed	MCA	Université M.S - Mascara

Année Universitaire : 2024-2025

Dédicace

*Louange à " Allah ", qui nous a permis de mener à bien cette thèse durant quatre années de travail, malgré les défis et les difficultés qui nous ont accompagnés. J'adresse également mes plus grands remerciements au directeur de thèse " **Pr. Boualem MERABET** " qui m'a proposé cette thèse et qui m'a donné la motivation et beaucoup de conseils précieux avec une orientation élevée, ainsi qu'à tous les professeurs de l'Université de Mascara, à mes parents le réconfort de mes yeux, qui ont travaillé dur; et ont été patients et ont dépensé tout ce qu'ils avaient pour que je puisse obtenir l'honneur de la science et du savoir et me guider vers le chemin de la réussite et de l'excellence. Enfin, je tiens à remercier tous mes collègues de cette formation doctorale, mes proches et tous ceux qui m'ont encouragé à atteindre cet objectif.*

Remerciements

Je tiens à remercier mon co-encadrant Dr.MOULAY Mohamed. Je remercie également tous les Membres du jury. Qu'ils veuillent trouver ici toute ma reconnaissance pour la peine qu'ils ont prise afin d'examiner et d'évaluer ce travail.

Je remercie tout le personnel des laboratoires LSTE de l'université de Mascara sans oublier tous les membres du département d'électronique de l'université Mustapha Stambouli de Mascara.

Table des matières

<i>Dédicace</i>	1
<i>Remerciements</i>	1
<i>Table des matières</i>	2
<i>Liste des figures</i>	5
<i>Liste des Tableaux</i>	6
Liste des Abréviations	7
<i>Introduction Générale</i>	11
CHAPITRE I	17
<i>L'évolution des communications mobiles de la 1G à la 5G : Etat de l'art</i>	17
I.1 Introduction	18
I.2 Génération de communication mobile : de la 1G à la 5G	19
2G.....	19
5G.....	19
I.3 Les normes de la 5G	24
I.4 Spectre et fréquence de la 5G.....	27
I.5 5G Applications et cas d'usage	28
I.5.1.1 Smart cities	30
I.5.1.2 Véhicules autonomes	30
I.5.1.3 E-santé	32
I.5.1.4 Robotique et automatisation dans le nuage	32
Expériences immersives	34
I.6 5G Les défis	35
I.6.1 Défis technologiques	36
I.6.1.1 Brouillage intercellulaire	36
I.6.1.2 Contrôle efficace de l'accès au support.....	36
I.6.1.3 Gestion du trafic.....	36
I.6.2 Défis communs.....	37
I.6.2.1 Services multiples.....	37
I.6.2.2 Infrastructure	37
I.6.2.3 Communication, navigation et détection	37
I.6.2.4 Sécurité et confidentialité	38
I.6.2.5 Législation du cyber droit	38
I.7 Conclusion	39
I.8 Références.....	40
CHAPITRE II	41

<i>Le Big Data et L'internet des objets IoT.....</i>	<i>41</i>
II.1 Introduction	42
II.2 L'évaluation du Big Data avec ses outils	43
II.3 Architecture du Big Data.....	43
II.3.1 Cadre de travail pour l'analyse du Big Data.....	43
II.4 Enjeux et défis.....	46
II.4.1 Volume	47
II.5 Outils d'analyse du Big Data	48
II. 6 Cas d'utilisation du big data	49
II.6.1 Banque et finance	50
II.6.2 Détection des fraudes.....	50
II.6.3 Division client et marketing personnalisé	50
II.6.4 Support client	51
II.6.5 Gestion des risques.....	52
II.6.6 Prévion de la valeur du temps de vie.....	53
II.6.7 Analyse de la cybersécurité	54
II.6.9 Secteur de la santé.....	55
II.6.2 Internet des objets IoT.....	57
II.7 La rencontre entre l'IoT et le Big Data	58
II.7.1 Plate-forme IoT.....	58
II.8 Rôle de l'apprentissage automatique pour le Big Data et l'IoT.....	60
II.9 Conclusion.....	62
II.10 Références	63
CHAPITRE III.....	66
<i>Classification de l'autisme par l'apprentissage profond</i>	<i>66</i>
III.1 Introduction	67
III.2 Historique des troubles du spectre autistique (TSA).....	67
III.3 L'apprentissage profond dans la recherche en neuro-imagerie	68
I. 4 Réseaux neuronaux convolutifs.....	70
III.4.6 Surajustement et régulation.....	77
III.5.2 Mise en œuvre du réseau.....	82
III.5.1 Approche	85
III.5.1 Mesures d'évaluation	87
III.5.2 Mesures d'évaluation	88
III.5.2.2 ROC-AUC	89
III.6 Résultats	91
III.6.1 Sélection des hyperparamètres	91
III.6.2 Résumé des performances.....	91
III.6.3 Complexité de l'échantillon.....	93
III.6.4 Convergence des pertes.....	94

III.7	Conclusion	95
III.8	Références	96
CHAPITRE IV		100
	<i>La géolocalisation intelligente des enfants autistes</i>	100
IV.1.	Introduction	101
IV.2.	Revue de la Littérature	101
IV.3.	Architecture du Système	101
IV.4.	Méthodologie	103
IV.5.	Résultat.....	104
IV.6.	Discussion	104
IV.7.	Conclusion et Perspectives Futures	105
IV.8.	Références	105
	<i>Conclusion générale</i>	107
	<i>Annexe</i>	108
	<i>Publications Internationales</i>	121
	<i>Conferences Internationales</i>	121

ملخص.....

ABSTRACT

RESUME

Liste des figures

Figure 1. 1 Evolution de la mobilité	19
Figure 1. 2 Architecture du GSM, de l'UMTS et du LTE.....	21
Figure 1. 3 Vision de l'UIT pour IMT2020.....	29
Figure 1. 4 Les opérateurs de réseau cherchent déjà à montrer ce que la 5G peut faire avec des projets tels que la ville intelligente d'Alba Iulia (crédit photo : ALBA IULIA)	30
Figure 1. 5 Véhicules autonomes.....	31
Figure 1. 6 Les défis technologiques de la 5G.....	37
Figure 1. 7 Les défis de la 5G	38
Figure 2. 1 Architecture du Big Data.....	46
Figure 2. 2 Les 10 V du big data.....	48
Figure 2. 3 Détection des fraudes à l'aide du big data.....	51
Figure 2. 4 Analyse et gestion des risques à l'aide du big data	53
Figure 2. 5 Manipulation du secteur des assurances à l'aide du big data	55
Figure 2. 6 Architecture IoT	58
Figure 3. 1 Architecture abstraite d'un réseau de neurones [16]	71
Figure 3. 2 Architecture générique des réseaux neuronaux convolutifs [15].....	71
Figure 3. 3 Opération Max Pool [15].....	74
Figure 3. 4 Représentation schématique du processus de rétropropagation [15].....	76
Figure 3. 5 Méthode de descente du gradient pour minimiser la fonction de perte [19].	76
Figure 3. 6 Dropout appliqué aux couches entièrement connectées.	78
Figure 3. 7 Fonction de perte d'entropie croisée.	84
Figure 3. 8 Courbes d'apprentissage CNN sur le résumé ReHo.	93
Figure 3. 9 Perte de validation pendant la formation ReHo.....	94
Figure 4. 1 Schéma illustrant l'architecture globale du système, depuis la collecte des données sur le terrain jusqu'à l'analyse en temps réel via des modèles de machine Learning	102
Figure 4. 2 Diagramme de flux détaillant le processus de collecte, de transmission et d'analyse des données. Cette figure illustre les interactions entre le Raspberry Pi, le réseau 5G et le module d'analyse basé sur la machine Learning.....	103
Figure annexe 1 Approches de cybersécurité pour les réseaux électriques assurant la continuité des services mobiles de 4G/5G H. BOUHAMIDA et al. 2021.....	109

Liste des Tableaux

Table 1 Contenu de la version 15 et de la version 16	25
Table 2 Caractéristiques de la version 17	26
Table 3 Nouvelles bandes pour l'introduction de NR (FR1).....	27
Table 4 Nouvelles bandes pour l'introduction de NR (FR2).....	28
Table 5 Symbole et taille de la mémoire : manipulée par le big data	43
Table 6 Évolution de l'analyse du Big Data.....	44
Table 7 Évolution des outils d'analyse du Big Data.....	45
Table 8 Les 10 V du big data détaillées	47
Table 9 Outils de big data	49
Table 10 Vue d'ensemble de tous les ensembles de données de synthèse	82
Table 11 Nombre d'échantillons dans les sous-ensembles après la division de l'ensemble de données	85
Table 12 scores de précision du test unique pour l'entraînement du CNN sur tous les résumés.	92

Liste des Abréviations

1

1G 1st Generation

2

2G 2nd Generation

3

3G 3rd Generation

3GPP 3rd Generation Partnership Project

4

4G 4th Generation

5

5G 5th Generation

5GSM 5G Session Management

5G-PPP 5G Public-Private Partnership

A

ABM Account Balance Management Function

AF Application Function

AI Artificial Intelligence

AKA Authentication and Key Agreement

AMF Access and Mobility Management Function

AMBR Aggregate Maximum Bit Rate

AMPS Advanced Mobile Phone System

API Application Programming Interface

APN Access Point Name

AR Augmented Reality

ARP Address Resolution Protocol

AS Access Stratum

AUSF Authentication Server Function

AWS Amazon Web Services

B

BD Billing Domain

BIOS Basic Input/Output System

BTS Base Transceiver Station

BMC Baseboard Management Controller

C

CA Carrier Aggregation

CDF Charging Data Function

CDR Charging Data Records

CGF Charging Gateway Function

CHF Charging Function

CIoT Cellular Internet of Things

CP Control Plane

CPU Central Processing Unit

CRUD Create, Read, Update, and Delete

CU Central Unit

CUPS Control and User Plane Separation

CSFB Circuit-Switched Fallback

D

D2D Device-to-Device

DB DataBase

DC Dual Connectivity

DCC Density based Clustering algorithm for Channel Allocation

DHCP Dynamic Host Configuration Protocol

DL Downlink

DN Data Network

DNN Data Network Name

DNS Domain Name System

DSS Dynamic Spectrum Sharing

DU Distributed Unit

E

EAP Extensible Authentication Protocol

EBI EPS Bearer ID

EDGE Enhanced Data Rates for GSM Evolution

eMBB Enhanced Mobile Broadband

EMS Element Managed Service

eMTC Enhanced machine-type communications

eNB The evolved Node B

EPC Evolved Packet Core
EPS Evolved Packet System
eSBA Enhanced Service-Based Architecture
ETSI European Telecommunications Standards Institute
EU European Union
E-UTRAN Evolved UMTS terrestrial radio access network

F

FAR Forwarding Action Rule
FR Frequency Range

G

GCC GNU Compiler Collection
GERAN GSM EDGE radio access network
GIT Global Information Tracker
GPRS General Packet Radio Service
GSM Global System for Mobile Communications
GTP GPRS Tunneling Protocol
GUAMI Globally Unique AMF ID
GUI Graphical User Interface
GUTI Globally Unique Temporary Identifier

H

HATEOAS Hypermedia as the Engine of Application State
HPLMN Home Public Land Mobile Network
HSPA High Speed Packet Access
HSS Home Subscriber Server
HTTP HyperText Transfer Protocol

I

IAB Integrated Access and Backhaul
IE Information Element
IEEE Institute of Electrical and Electronics Engineers
IMS IP Multimedia Subsystem
IMSI International Mobile Subscriber Identity
IMT-2000 International Mobile Telecommunications 2000

IMT-2020 International Mobile Telecommunications 2020
IoT Internet of Things
IP Internet Protocol
IPMI Intelligent Power Management Interface
IPv4 Internet Protocol version 4
IPv6 Internet Protocol version 6
IPX Internetwork Packet Exchange
ITS Intelligent Transport System
ITU International Telecommunication Union
ITU-R International Telecommunication Union - Radiocommunication Sector

J

JOSE Javascript Object Signing and Encryption
JSON JavaScript Object Notation

K

KPI Key Performance Indicators

L

LAA License Assisted Access
LI Lawful Interception
LMF Location Management Services
LTE Long Term Evolution
LWA LTE WLAN aggregation
LXC Linux Containers

M

M2M Machine to Machine
MaaS Metal-as-a-Service
MAC Medium Access Control
MANO Management & Orchestration
MC Mission Critical
MCC Mobile Country Code
MDS MPS Multimedia Priority Service
MEC Multi-access Edge Computing
MeNB Master eNB
MIB Master Information Block
MIMO Multiple-Input/Multiple-Output
MME Mobility Management Entity

mMTC *massive Machine Type Communication*
MNC *Mobile Network Code*
MNO *Mobile Network Operators*
MPS *Multimedia Priority Service*
MSIN *Mobile Subscription Identification Number*
MTC *Machine Type Communications*
MT-SMS *Mobile terminated SMS*

N

NAI *Network Access Identifier*
NAS *Non-Access Stratum*
NAT *Network Address Translation*
NB-IoT *Narrowband Internet of Things*
NEF *Network Exposure Function*
NF *Network Function*
NFV *Network Functions Virtualisation*
NGAP *Next Generation Application Protocol*
ng-eNB *Next Generation e-NodeB*
NG-RAN *Next Generation Radio Access Network*
NIC *Network Interface Card*
NMT *Nordic Mobile Telephone*
NR *New Radio*
NRF *Network Repository Function*
NSA *Non-standalone*
NSSAI *Network Slice Selection Assistance Information*
NSSF *Network Slice Selection Function*
NTN *Non-Terrestrial Networks*
NWDAF *Network Data Analytics Services*

O

OCF *Online Charging Function*
OCS *Online Charging System*
OFDM *Orthogonal Frequency Division Multiplexing*
OS *Operating System*

P

P-CSCF *Proxy-Call Session Control Function*
PCC *Packet Core Controller*

PCF *Policy Control Function*
PCO *Protocol Configuration Options*
PCRF *Policy and Charging Rules Function*
PDCP *Packet Data Convergence Protocol*
PDN *Packet Data Network*
PDR *Packet Detection Rule*
PDU *Packet Data Unit*
PFCP *Packet Forwarding Control Protocol*
PFD *Packet Flow Description*
PGW *Packet Data Network Gateway*
PHY *Physical layer*
PIM *Physical Infrastructure Manager*
PLC *Programmable Logic Controllers*
PLMN *Public Land Mobile Network*
ProSe *Proximity Services*
PXE *Preboot Execution Environment*

Q

QEMU *Quick EMUlator*
QER *QoS Enforcement Rules*
QFI *QoS Flow ID*
QoS *Quality of Service*

R

RAN *Radio Access Network*
RAT *Radio Access Technology*
REST *Representational State Transfer*
RF *Rating Function*
RLC *Radio Link Control*
RRC *Radio Resource Control*
RRM *Radio Resource Management*

S

S-NSSAI *Single – Network Slice Selection Assistance*
SA *Standalone*
SBA *Service Based Architecture*
SBI *Service Based Interface*
SCP *Service Communication Proxy*
SDAP *Service Data Adaptation Protocol*

SDFService Data Flow
SDMSubscriber Data Management
SDNSoftware-Defined Networking
SEEPSecurity Edge Protection Proxy
SeNBSecondary evolved Node B
SGWServing Gateway
SIMSubscriber Identity Module
SIMService Infrastructure Manager
SLSidelink
SLAService-Level Agreement
SMSession Management
SMFSession Management Function
SMSSShort Message Service
SONSelf-Organizing Networks
SRVCCSingle Radio Voice Call Continuity
SSCSession and Service Continuity
SUCISubscription Concealed Identifier
SUPISubscription Permanent Identifier

T

TATiming Advance
TACTracking Area Code
TACSTotal Access Communication System
TAITracking Area Identification
TCPTransmission Control Protocol
TDSCDMATime Division Synchronous Code Division Multiple Access
TEIDTunnel Endpoint Identifier
TFTPTrivial File Transfer Protocol
TMSITemporary Mobile Subscriber Identity
TOSCATopology and Orchestration Specification for Cloud Applications
TSTechnical Specification
TSNTime Sensitive Network

U

UCLCUplink Classifier
UDMUnified Data Management
UDPUser Datagram Protocol

UDRUnified Data Repository
UEUser Equipment
UECMUE Context Management
ULUplink
ULIUser Location Information
UMTSUniversal Mobile Telecommunication System
UPFUser Plane Function
URLUniform Resource Locator
uRLLCUltra-Reliable Low Latency Communications
URRUsage Reporting Rules
UTRANUMTS Terrestrial Radio Access Network

V

V2XVehicle to everything
VMVirtual Machine
VIMVirtual Infrastructure Manager
VLANVirtual LAN
VNFVirtualized Network Functions
VNFMVirtual Network Functions Manager
VoIPVoice over IP
VoLTEVoice over LTE
VoNRVoice over 5G New Radio
VPLMNVisited Public Land Mobile Network
VRVirtual Reality

W

WCDMAWideband Code Division Multiple Access
Wi-FiWireless Fidelity
Wi-MAXWorldwide Interoperability for Microwave Access
WLANWireless Local Area Network

X

XReExtended Reality

Z

ZSSZone Synchronization Service

Introduction Générale

Presque toute entreprise de télécommunications planifie la transition vers la cinquième génération (5G). Cette transition est bien plus que la fabrication d'une vitesse plus rapide. La 5G permet de nouvelles expériences en internet des objets (IoT), une connectivité massive, des villes intelligentes, une autonomie de dix ans, des réseaux ultra-réactifs et une vitesse accrue, et nécessite un changement important dans l'architecture des réseaux radio, de transport, des centres de données et du cœur de réseau, ainsi qu'un changement dans l'équipement des utilisateurs [1].

La quantité de plus en plus importante d'informations numériques étiquetées, disponibles dans presque tous les domaines de la technologie, a fait faire des bonds importants au développement de l'intelligence artificielle (IA) et notamment des méthodes d'apprentissage et en particulier des méthodes d'apprentissage automatique (MAA) [2]. Ces techniques d'IA ont tiré pleinement parti de cette émergence du "big data" et ont ensuite obtenu des résultats impressionnants dans de nombreux domaines différents [3, 4]. L'un de ces domaines est le secteur des soins de santé, qui, en raison de sa richesse en données et processus complexes, offre des perspectives intéressantes pour la mise en œuvre de techniques modernes d'apprentissage automatique [3]. Un domaine d'intérêt particulier pour l'application de l'IA dans le domaine médical est celui de la recherche en neuro-imagerie psychiatrique [5].

Les principaux objectifs de ce domaine de recherche sont d'étudier la connectivité fonctionnelle du cerveau humain et d'identifier des biomarqueurs objectifs qui peuvent contribuer au diagnostic et le traitement de troubles cérébraux tels que la maladie d'Alzheimer, le TDAH, l'autisme et les accidents cérébraux et les accidents vasculaires cérébraux [6]. De plus, l'imagerie par résonance magnétique fonctionnelle à l'état de repos (rs-fMRI) [7] est devenue la technique de neuro-imagerie la plus populaire pour étudier la connectivité fonctionnelle du cerveau [8-11]. Les données du connectome, pouvant être obtenues par des techniques d'IRMf, constituent une riche source de données de neuro-imagerie représentant la connectivité fonctionnelle du cerveau humain. Par conséquent, l'application d'algorithmes d'apprentissage automatique à ces données d'imagerie cérébrale spécifiques présente un grand potentiel [12]. Plus précisément, l'application de MAA à des tâches de classification utilisant des données d'IRMf pourrait améliorer la précision du diagnostic divers troubles psychiatriques et neurologiques, accélérer le processus de diagnostic et aider à dévoiler les schémas cérébraux pathologiques cachés qui servent de biomarqueurs pour le traitement des maladies des troubles cérébraux [13-17].

Diverses techniques d'apprentissage automatique ont été appliquées dans le contexte de la recherche en neuro-imagerie avec différents niveaux de succès. Récemment, cependant, une famille particulière de méthodes d'apprentissage automatique, connue sous le nom d'apprentissage profond, a fait l'objet d'une attention considérable, car ces techniques d'apprentissage profond ont donné des résultats impressionnants dans un grand nombre de domaines. Comme la classification d'images et la reconnaissance vocale [18].

En outre, les techniques d'apprentissage profond sont devenues une méthode de choix de plus en plus populaire dans la recherche en neuro-imagerie parce qu'elles sont particulièrement efficaces pour extraire des modèles et des caractéristiques subtiles des données [19-23]. Dans le cadre de l'essor récent de l'application des méthodes d'apprentissage profond dans le contexte de la neuroimagerie, des recherches récentes ont montré que les réseaux de neurones convolutionnels (CNN) ont généré les résultats les plus encourageants dans la classification et la prédiction des troubles psychiatriques et neurologiques [24].

Les CNN sont une classe spécifique de réseaux neuronaux profonds, qui est devenue une méthode populaire et couramment utilisée dans les tâches de vision par ordinateur et de classification d'images [25].

Une première approche de cette thèse vient répondre à la problématique de prédire de nouvelles solutions pour quantifier les anomalies de langage chez l'enfant autiste, et de le localiser intelligemment en cas de perte (ou kidnapping).

Elle repose sur un ensemble de propositions de concepts en conception de réseaux de télécoms. Notre première contribution est désécuriser la téléphonie IP pour les spécialistes Institut de l'Autisme. La seconde, très liée à la première, est de répondre aux exigences d'IoT pour les réseaux de télécommunication, et remédier aux problèmes d'interruption de consommation en énergie électrique perturbant ces réseaux, spécialement dans les régions éloignées, en adoptant l'alternative photovoltaïque pouvant dominer dans notre pays. L'état de l'art de l'évolution des communications mobiles de la 1G à la 5G a fait l'objet de notre premier chapitre. Le Big Data et l'Io maitrisant les réseaux conçus pour la géolocalisation sont donnés au chapitre II. L'interrelation entre les troubles du spectre autistique et la technique fonctionnelle de neuro-imagerie (IRM), et la classification de l'autisme par l'apprentissage profond a fait l'objet du troisième chapitre. Le quatrième et dernier chapitre est consacré à la discussion des résultats prédisant le statut autistique lors de l'entraînement sur une sélection variée de clips audio domestiques aux qualités d'enregistrement inégales, ce qui pourrait être plus généralisable aux conditions du monde réel.

Enfin, cette thèse est achevée par une conclusion générale, et des perspectives faisant l'objet de sa deuxième approche (au future proche) sont listées.

Références

- [1] Simsek, Meryem, Adnan Aijaz, Mischa Dohler, Joachim Sachs, and Gerhard Fettweis. "5G-enabled tactile internet." *IEEE Journal on Selected Areas in Communications* 34, no. 3 (2016): 460-473. Varga, Pal, Jozsef Peto, Attila Franko, David Balla, David Haja, Ferenc Janky, Gabor Soos, Daniel Ficzer, Markosz Maliosz, and Laszlo Toka. "5g support for industrial iot applications—challenges, solutions, and research gaps." *Sensors* 20, no. 3 (2020): 828. countries: A note for policy makers." *Telecommunications Policy* 44, no. 7 (2020): 101975.
- [2] Antonopoulos, Ioannis, Valentin Robu, Benoit Couraud, Desen Kirli, Sonam Norbu, Aristides Kiprakis, David Flynn, Sergio Elizondo-Gonzalez, and Steve Wattam. "Artificial intelligence and machine learning approaches to energy demand-side response: A systematic review." *Renewable and Sustainable Energy Reviews* 130 (2020): 109899. Sarker, Iqbal H. "Machine learning: Algorithms, real-world applications and research directions." *SN Computer Science* 2, no. 3 (2021): 1-21.
- [3] Faccia, Alessio, Mohamed Yousif Khamis Al Naqbi, and Saeed Ahmad Lootah. "Integrated cloud financial accounting cycle: how artificial intelligence, Blockchain, and XBRL will change the accounting, fiscal and auditing practices." In *Proceedings of the 2019 3rd International Conference on Cloud and Big Data Computing*, pp. 31-37. 2019.
- [4] Aggarwal, Puneet Kumar, Parita Jain, Jaya Mehta, Riya Garg, Kshirja Makar, and Poorvi Chaudhary. "Machine learning, data mining, and big data analytics for 5G-enabled IoT." In *Blockchain for 5G-Enabled IoT*, pp. 351-375. Springer, Cham, 2021.
- [5] Lin, Eugene, Chieh-Hsin Lin, and Hsien-Yuan Lane. "Precision psychiatry applications with pharmacogenomics: Artificial intelligence and machine learning approaches." *International journal of molecular sciences* 21, no. 3 (2020): 969.
- [6] Sakai, Koji, and Kei Yamada. "Machine learning studies on major brain diseases: 5-year trends of 2014–2018." *Japanese journal of radiology* 37, no. 1 (2019): 34-72.
- [7] Ellard, Kristen K., Sofia Uribe, and Christopher J. Funes. "Resting-state functional magnetic resonance imaging (rsfMRI) in bipolar and unipolar depression." In *The Neuroscience of Depression*, pp. 277-299. Academic Press, 2021.
- [8] Ferreira, Luiz Kobuti, and Geraldo F. Busatto. "Resting-state functional connectivity in normal brain aging." *Neuroscience & Biobehavioral Reviews* 37, no. 3 (2013): 384-400.
- [9] Hull, Jocelyn V., Lisa B. Dokovna, Zachary J. Jacokes, Carinna M. Torgerson, Andrei Irimia, and John Darrell Van Horn. "Resting-state functional connectivity in autism spectrum disorders: a review." *Frontiers in psychiatry* 7 (2017): 205.
- [10] Jiang, Wenyan, Yiwu Lei, Jing Wei, Lu Yang, Shubao Wei, Qiong Yin, Shuguang Luo, and Wenbin Guo. "Alterations of interhemispheric functional connectivity and degree centrality in cervical dystonia: a resting-state fMRI study." *Neural Plasticity* 2019 (2019).
- [11] Yang, Xin, Ning Zhang, and Paul Schrader. "A study of brain networks for autism spectrum disorder classification using resting-state functional connectivity." *Machine Learning with Applications* 8 (2022): 100290.
- [12] Lei, Du, Walter HL Pinaya, Therese Van Amelsvoort, Machteld Marcelis, Gary Donohoe, David O. Mothersill, Aiden Corvin et al. "Detecting schizophrenia at the level of the individual:

- relative diagnostic value of whole-brain images, connectome-wide functional connectivity and graph-based metrics." *Psychological medicine* 50, no. 11 (2020): 1852-1861.
- [13] Noor, Manan Binth Taj, Nusrat Zerine Zenia, M. Shamim Kaiser, Shamim Al Mamun, and Mufti Mahmud. "Application of deep learning in detecting neurological disorders from magnetic resonance images: a survey on the detection of Alzheimer's disease, Parkinson's disease and schizophrenia." *Brain informatics* 7, no. 1 (2020): 1-21.
- [14] Chang, Chun-Hung, Chieh-Hsin Lin, and Hsien-Yuan Lane. "Machine learning and novel biomarkers for the diagnosis of Alzheimer's disease." *International Journal of Molecular Sciences* 22, no. 5 (2021): 2761.
- [15] Yin, Wutao, Longhai Li, and Fang-Xiang Wu. "Deep learning for brain disorder diagnosis based on fMRI images." *Neurocomputing* 469 (2022): 332-345.
- [16] Galety, Mohammad Gouse, and Shweta Gupta. "Artificial Intelligence in the Detection of Alzheimer's Disease." In *Bio-Inspired Algorithms and Devices for Treatment of Cognitive Diseases Using Future Technologies*, pp. 136-155. IGI Global, 2022.
- [17] Ching, Christopher RK, Derrek P. Hibar, Tiril P. Gurholt, Abraham Nunes, Sophia I. Thomopoulos, Christoph Abé, Ingrid Agartz et al. "What we learn about bipolar disorder from large-scale neuroimaging: Findings and future directions from the ENIGMA Bipolar Disorder Working Group." *Human brain mapping* 43, no. 1 (2022): 56-82.
- [18] Albawi, Saad, Tareq Abed Mohammed, and Saad Al-Zawi. "Understanding of a convolutional neural network." In *2017 international conference on engineering and technology (ICET)*, pp. 1-6. IEEE, 2017.
- [19] Vieira, Sandra, Walter HL Pinaya, and Andrea Mechelli. "Using deep learning to investigate the neuroimaging correlates of psychiatric and neurological disorders: Methods and applications." *Neuroscience & Biobehavioral Reviews* 74 (2017): 58-75.
- [20] Bzdok, Danilo, and Andreas Meyer-Lindenberg. "Machine learning for precision psychiatry: opportunities and challenges." *Biological Psychiatry: Cognitive Neuroscience and Neuroimaging* 3, no. 3 (2018): 223-230.
- [21] Saccà, Valeria, Alessia Sarica, Fabiana Novellino, Stefania Barone, Tiziana Tallarico, Enrica Filippelli, Alfredo Granata et al. "Evaluation of machine learning algorithms performance for the prediction of early multiple sclerosis from resting-state FMRI connectivity data." *Brain imaging and behavior* 13, no. 4 (2019): 1103-1114.
- [22] Beers, Andrew, James Brown, Ken Chang, Katharina Hoebel, Jay Patel, K. Ina Ly, Sara M. Tolaney et al. "DeepNeuro: an open-source deep learning toolbox for neuroimaging." *Neuroinformatics* 19, no. 1 (2021): 127-140.
- [23] Quaak, Mirjam, Laurens van de Mortel, Rajat Mani Thomas, and Guido van Wingen. "Deep learning applications for the classification of psychiatric disorders using neuroimaging data: systematic review and meta-analysis." *NeuroImage: Clinical* 30 (2021): 102584.
- [24] Oh, Kanghan, Young-Chul Chung, Ko Woon Kim, Woo-Sung Kim, and Il-Seok Oh. "Classification and visualization of Alzheimer's disease using volumetric convolutional neural network and transfer learning." *Scientific Reports* 9, no. 1 (2019): 1-16.
- [25] Yamashita, Rikiya, Mizuho Nishio, Richard Kinh Gian Do, and Kaori Togashi. "Convolutional neural networks: an overview and application in radiology." *Insights into imaging* 9, no. 4 (2018): 611-629.

CHAPITRE I

*L'évolution des communications
mobiles de la 1G à la 5G :
Etat de l'art*

I.1 Introduction

La 5G est la 5e génération de réseau mobile. Il s'agit d'une nouvelle norme sans fil mondiale après les réseaux 1G, 2G, 3G et 4G. La 5G permet un nouveau type de réseau conçu pour connecter virtuellement tout le monde et tout ce qui existe, y compris les machines, les objets et les appareils [1].

La technologie sans fil 5G est censée offrir à un plus grand nombre d'utilisateurs des débits de pointe supérieurs de plusieurs Gbps, une latence ultra faible, une plus grande fiabilité, une capacité de réseau massive, une disponibilité accrue et une expérience utilisateur plus uniforme. Des performances plus élevées et une efficacité améliorée permettent de nouvelles expériences utilisateur et connectent de nouvelles industries.

Alors que la 4G LTE se concentrait sur la fourniture de services haut débit mobile beaucoup plus rapides que la 3G, la 5G est conçue pour être une plateforme unifiée et plus performante qui non seulement élève les expériences haut débit mobile, mais prend également en charge de nouveaux services tels que les communications critiques et l'IoT massif. La 5G peut également prendre en charge de manière native tous les types de spectre (sous licence, partagé, sans licence) et toutes les bandes (basse, moyenne, haute), un large éventail de modèles de déploiement (des macro-cellules traditionnelles aux hotspots) et de nouveaux modes d'interconnexion (tels que les interconnexions entre appareils et les maillages à bonds multiples) [2].

I.2 Génération de communication mobile : de la 1G à la 5G

Au cours des 40 dernières années, le monde a connu cinq générations de communications mobiles comme illustré sur la figure 1.1.

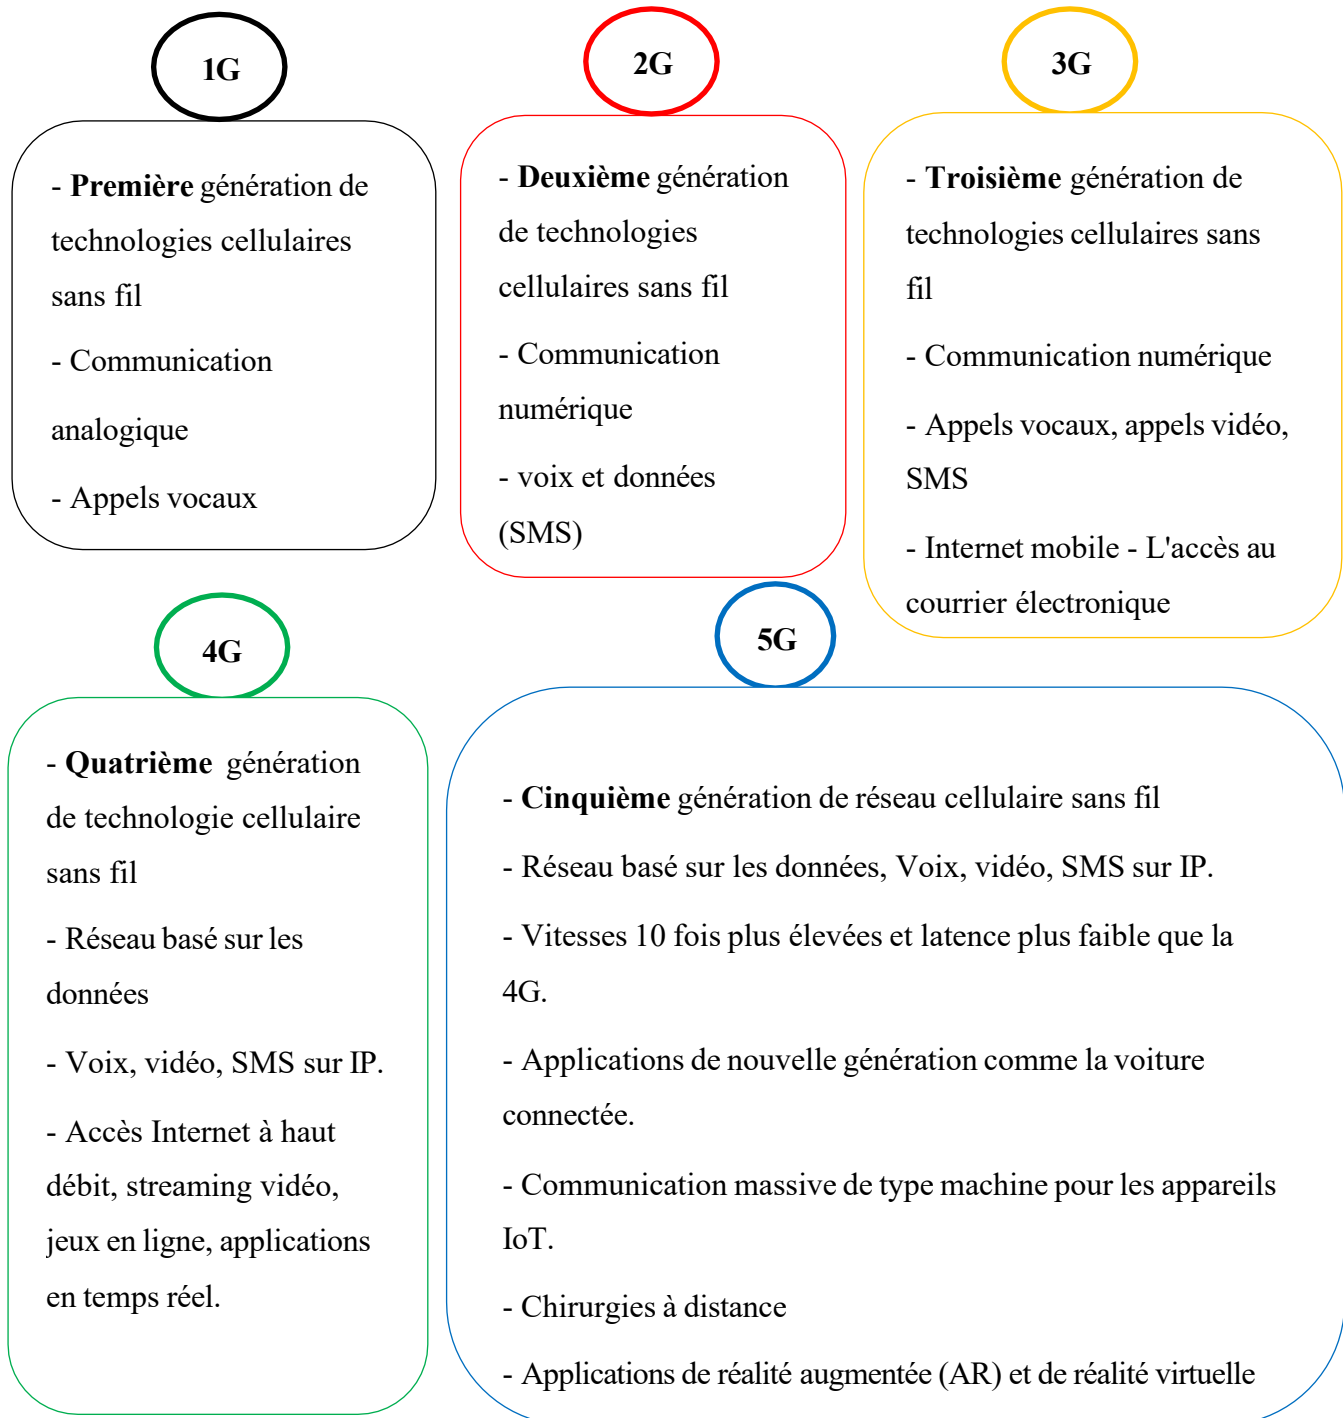


Figure 1. 1 Evolution de la mobilité

Le terme "génération" est introduit par l'industrie : il n'a pas de signification formelle, mais il est surtout synonyme d'une interface radio moderne et d'une nouvelle architecture de réseau.

Les systèmes de première génération (1G) utilisaient des techniques de communication analogiques similaires à celles de la radio analogique traditionnelle. Les cellules individuelles étaient géantes, et les systèmes ne pouvaient pas utiliser efficacement le spectre radioélectrique disponible, de sorte que leur capacité était limitée par rapport aux normes actuelles. Les systèmes de communication mobile basés sur la technologie de première génération étaient limités aux services vocaux, et les appareils mobiles étaient volumineux et coûteux. Ils étaient presque entièrement destinés aux utilisateurs professionnels. Le Nordic Mobile Telephone (NMT) en Scandinavie, l'Advanced Mobile Phone System (AMPS) aux États-Unis et le Total Access Communication System (TACS) au Royaume-Uni étaient tous des systèmes populaires.

Deuxième génération de communication mobile, apparue au début des années 1990 [3]. Dans cette génération, les télécommunications mobiles sont devenues un produit de consommation. Ce furent les premiers systèmes à utiliser les technologies numériques, qui ont permis une utilisation plus efficace du spectre radioélectrique et la création d'appareils plus petits et moins chers. Le système mondial de communications mobiles (GSM), produit par l'Institut européen des normes de télécommunications (ETSI), était le système 2G le plus populaire. Le GSM était initialement destiné uniquement à la communication vocale. Mais il a ensuite été étendu pour fournir une messagerie instantanée via le Short Message Service (SMS) et la livraison de données par paquets aux appareils mobiles via le General Packet Radio Service (GPRS). Une autre amélioration a été apportée par le système EDGE (Enhanced Data Rates for GSM Evolution), qui a modifié l'interface radio pour augmenter le débit de données disponible. Le réseau central du GSM comporte les deux domaines traditionnels : le domaine à commutation de circuits pour les appels vocaux et le domaine à commutation de paquets pour les données. Le RAN est connu sous le nom de réseau d'accès radio GSM EDGE (GERAN), tandis que la station de base est appelée station émettrice-réceptrice de base (BTS) [4] L'architecture GSM de haut niveau et ses descendants sont représentés à la figure I.2.




Figure 1. 2 Architecture du GSM, de l'UMTS et du LTE

Grâce au succès de la 2G, l'Union internationale des télécommunications (UIT) a publié en 1997 un ensemble d'exigences pour un système de communication mobile de troisième génération (3G), sous le nom de Télécommunications mobiles internationales (IMT) 2000 (IMT-2000) [5]. Divers organismes de normalisation ont répondu en soumettant des spécifications, que l'UIT a finalement acceptées comme répondant aux exigences de l'IMT-2000. La plus populaire était le système de télécommunication mobile universel (UMTS), développé par le projet de partenariat de troisième génération (3GPP) [6], une collaboration spécialement formée qui a ensuite repris les spécifications du GSM. L'UMTS dispose du même réseau central que le GSM, mais d'un réseau d'accès radio (RAN) moderne appelé réseau d'accès radio terrestre UMTS (UTRAN) et d'une nouvelle station de base appelée Node B. L'interface radio UMTS surpasse l'interface radio GSM. Elle comprend deux parties : WCDMA (wideband code division multiple access) est largement utilisé dans le monde entier & Time-division synchronous code division multiple access (TD-SCDMA), d'autre part, est dérivé du WCDMA, et il est principalement utilisé en Chine. Par la suite, l'amélioration la plus efficace est appelée accès par paquets à haut débit (HSPA) qui améliore les performances des applications de données en augmentant le débit moyen de l'interface radio au détriment de la variation à court terme du débit de données pour un utilisateur individuel.

L'introduction du HSPA a coïncidé avec celle des smartphones, dont le plus célèbre est l'iPhone d'Apple en 2007, suivi des appareils basés sur le système d'exploitation Android de Google en 2008. Sous l'effet de ces facteurs, l'utilisation des applications de données mobiles et le volume du trafic de données mobiles ont explosé. Par conséquent, les réseaux de quatrième génération (4G) ont été optimisés pour la transmission de données.

Il existe deux systèmes 4G. Les États-Unis ont développé le système Wi-MAX (Worldwide Interoperability for Microwave Access) utilisant le multiplexage par répartition en fréquence orthogonale (OFDM), issu du Wi-Fi. L'autre est le système LTE qui a été développé après le WiMAX. La technologie du LTE et celle du WiMAX sont très similaires. La bande passante des deux systèmes est de 20 MHz [7].

Le système 3GPP connu sous le nom de Long-term Evolution (LTE) est de loin le plus populaire. Le nœud B évolué (eNB) est la station de base dans le LTE, le réseau d'accès radio terrestre UMTS évolué (E-UTRAN) est le RAN et le noyau de paquets évolué (EPC) est un remplacement direct du domaine de commutation par paquets de l'UMTS et du GSM. Le système de paquets évolué (EPS) est le nom officiel de l'ensemble du système. Toutefois, ce terme n'est utilisé qu'occasionnellement. Bien que le LTE ne dispose pas de son propre domaine à commutation de circuits, il existe toujours de nombreuses façons pour un utilisateur LTE de passer un appel vocal. La première est le repli à commutation de circuits (CSFB), dans lequel le réseau fait basculer le mobile vers une cellule 2G ou 3G existante, à partir de laquelle le mobile se connecte au domaine CS du cœur 2G ou 3G. Le mobile peut aussi utiliser un service tiers comme Skype ou WhatsApp pour passer un appel VoIP (voix sur IP) via l'EPC. Enfin, les fournisseurs de réseaux peuvent proposer leurs propres services vocaux IP via un réseau 3GPP externe appelé sous-système multimédia IP (IMS), dans une technologie connue sous le nom de voix sur LTE (VoLTE). Malgré sa complexité, l'IMS offre plusieurs avantages, notamment la possibilité de gérer des services tels que les appels d'urgence qui ne sont pas fournis par des applications tierces, la possibilité de maintenir les revenus de la voix et la possibilité de libérer les fournisseurs de réseaux de leur dépendance vis-à-vis des cellules 2G ou 3G situées à proximité. Il prend également en charge une technique connue sous le nom de continuité d'appel vocal par radio unique (SRVCC), dans laquelle le réseau peut déplacer un téléphone mobile vers une cellule 2G ou 3G s'il sort de la zone de couverture LTE et transformer un appel VoIP en cours en un appel à commutation de circuits géré par le cœur 2G ou 3G.

En 2008, l'UIT a annoncé des exigences pour l'IMT-Advanced [8], qui est le successeur de l'IMT-2000. Les exigences demandaient des débits de données maximaux en liaison descendante et en liaison ascendante de 1000 et 500 Mbps, respectivement, au-delà des capacités du LTE. En conséquence, le 3GPP a réagi en rédigeant des spécifications pour une version améliorée du LTE, appelée LTE-Advanced. L'amélioration la plus importante du LTE-Advanced est connue sous le nom d'agrégation de porteuses (CA). Cette technique améliore le débit de

données d'un mobile en lui permettant de communiquer par le biais de plusieurs cellules, chacune émettant et recevant sur une fréquence radio différente, mais toujours gérée par un seul eNB. La double connectivité (DC) est une amélioration ultérieure qui permet à ces cellules d'être contrôlées par deux stations de base distinctes plutôt que par une seule. La station de base d'origine achemine le trafic pour l'utilisateur ainsi que les messages de signalisation qui contrôlent le mobile ; elle est appelée eNB maître (MeNB). En général, la MeNB contrôle une ou plusieurs macrocellules, qui fournissent une couverture étendue et des communications fiables au mobile. La station de base supplémentaire est appelée eNB secondaire (SeNB), qui transporte principalement le trafic. Elle contrôle une ou plusieurs microcellules, qui fournissent aux mobiles qui peuvent les recevoir un débit de données beaucoup plus élevé. La double connectivité n'a pas été largement adoptée au départ, mais elle constitue une étape essentielle vers le déploiement de la 5G. LTE-Advanced Pro est le nom donné aux améliorations ultérieures du LTE. Ces améliorations étendent les capacités du LTE et les services qu'il fournira, et elles agissent comme un précurseur de la 5G. La technologie LTE ayant été conçue pour être utilisée par des personnes, des dispositifs tels que les trackers de véhicules et les compteurs intelligents de services publics répondent aux besoins en matière de communications de type machine (MTC) sur de vastes zones. La technologie LTE comprend deux améliorations pour prendre en charge ces dispositifs. Les communications améliorées de type machine (eMTC) sont rétrocompatibles avec le LTE en ce sens qu'une station de base eMTC se connectera simultanément aux mobiles et aux dispositifs de type machine existants. L'internet des objets à bande étroite (NB-IoT) offre de meilleures performances, mais il est identifié comme une technologie d'interface radio distincte qui n'est pas rétrocompatible avec le LTE : une station de base NB-IoT ne peut pas se connecter aux anciens mobiles et vice versa. Les spécifications LTE ont toujours permis à un réseau d'accès non 3GPP de se connecter au noyau de paquets évolué. Le choix le plus courant est un réseau local sans fil (WLAN), également appelé WiFi, défini par l'Institute of Electrical and Electronics Engineers (IEEE) dans un ensemble de normes appelé IEEE 802.11. Des améliorations ultérieures ont été apportées à cette capacité de diverses manières. L'accès assisté par licence (LAA) est basé sur l'agrégation de porteuses, introduisant des cellules LTE supplémentaires dans le spectre sans licence utilisé pour le WiFi. L'agrégation LTE WLAN (LWA) est axée sur la double connectivité, mais au lieu d'un eNB maître et d'un eNB secondaire, le mobile se connecte à un eNB maître et à un point d'accès WiFi. La communication de dispositif à dispositif (D2D), également connue sous le nom de services de proximité (ProSe), permet à deux téléphones mobiles de se connecter directement par le biais d'une nouvelle interface radio appelée sidelink (SL). La première utilisation concerne les réseaux de sécurité publique, tels que ceux utilisés par la police et d'autres services d'urgence. Cette communication est essentielle, que la station de base soit en panne en raison d'une urgence ou qu'elle soit tout simplement hors de contrôle.

La communication D2D est également un excellent moyen de décharger le trafic vers la station de base pour le partage de fichiers entre appareils proches. Le sidelink est également un aspect essentiel des communications entre véhicules ou de l'échange de données depuis et vers un véhicule routier. Bien que la 5G soit nécessaire pour une prise en charge complète des communications entre véhicules, la LTE peut prendre en charge certains aspects moins stricts et non critiques pour la sécurité. Les améliorations comprennent la prise en charge de l'architecture de l'ETSI pour un système de transport intelligent (ITS), ainsi que des améliorations de la liaison latérale pour permettre aux véhicules de se connecter même lorsque leurs vitesses relatives sont élevées.

Lors de la Conférence mondiale des radiocommunications 2015 qui s'est tenue à Genève, en Suisse, l'UIT-R a officiellement approuvé trois résolutions visant à faciliter le futur processus de recherche sur la 5G et a officiellement déterminé que le nom de la 5G est "IMT-2020".

Avec la clôture de la dernière décennie et dans les années 2020, nous allons connaître l'essor de la 5e génération de réseaux mobiles. Il s'agit d'un établissement innovant totalement nouveau, construit dans le but de réaliser la prochaine grande vague d'avancées numériques qui changeront la vie et qui seront rendues possibles par notre avenir intelligent et connecté, qu'il s'agisse des avantages de la conduite autonome en termes de santé, de sécurité et d'environnement, de l'essor considérable de l'IA via l'apprentissage automatique, d'une toute nouvelle génération de soins de santé ou d'une révolution intelligente et connectée qui transformera l'agriculture, la fabrication, les villes et nos foyers.

I.3 Les normes de la 5G

Définir une nouvelle norme complète pour la 5G est une entreprise de grande envergure. Le 3GPP a divisé la norme 5G en deux versions : la version 15 et la version 16.

Avec la version 15, la norme 3GPP a jeté les bases de la nouvelle radio (NR) et des réseaux 5G non autonomes (NSA) qui s'appuient sur les réseaux centraux LTE existants ; cette version a été lancée en 2018. Elle a également défini certaines améliorations du cœur LTE, telles que la séparation des plans de contrôle et d'utilisateur, afin de mieux s'adapter à l'adoption de la 5G. Les réseaux centraux autonomes (SA) 5G ont également été détaillés dans la version 15. La version 16, qui est sortie en juin 2020, a ajouté davantage de fonctionnalités 5G.

La principale différence entre la 4G et la 5G en termes d'infrastructure est que la 4G a initié la transition vers un réseau virtualisé, tandis que la 5G l'a poussée encore plus loin vers une infrastructure conteneurisée.

Les détails de la version 16 sont représentés dans le tableau 1.1.

Version 15	Version 16
- NR- Nouvelle radio - NR NSA, radio 5G pour travailler avec le noyau LTE - NR SA, 5G Radio pour travailler avec le noyau 5G - MTC massif et Internet des objets - Communication entre véhicules et objets (V2x) - Interconnexion des systèmes essentiels à la mission (MC) avec les systèmes existants - Utilisation du spectre sans licence pour les WLAN - Découpage - réseaux logiques et de bout en bout - Exposition aux API - accès de tiers aux services 5G - Architecture basée sur les services (SBA) - Nouvelles améliorations du LTE - Système de communication mobile pour les chemins de fer - MEC	- Radio - NR dans une bande sans licence - IOT industriel - Positionnement précis de la RN - NR pour l'accès et le backhaul intégrés (IAB) - Noyau 5G - SBA amélioré (eSBA) - Réseaux privés - Convergence sans fil/filaire (câble/BNG) + orientation de l'accès - Réseau sensible au temps (TSN) - IoT cellulaire (NB-IOT, CatM) - Gestion des tranches - Analyse des réseaux - V2x Phase 3 : capteurs étendus pour le platooning, conduite automatisée, conduite à distance - Améliorations de l'URLLC

Table 1 Contenu de la version 15 et de la version 16

En 2022, la version 17 devrait être publiée. Elle introduit un ensemble complet de fonctionnalités qui annonceraient véritablement l'arrivée de la 5G. (voir Tableau 1.2)

Version 17	
- NR MIMO - Amélioration des liaisons secondaires NR - 52,6 - 71 GHz avec la forme d'onde existante - Amélioration du partage dynamique du spectre (DSS). Amélioration de l'IoT industriel / URLLC - Étude - IoT sur réseaux non terrestres (NTN) NR sur réseaux non terrestres (NTN) - Amélioration du positionnement NR - Dispositifs NR peu complexes Économie d'énergie - Amélioration de la couverture des RN - Étude - NR eXtended Reality (XR) Amélioration NB-IoT et LTE-MTC. - 5G Amélioration de la diffusion multicast multiradio DCCA - Multi SIM - Amélioration de l'accès intégré et du backhaul (IAB) - Systèmes aériens sans pilote - Services de localisation 5GC - Service prioritaire multimédia (MPS) - Services de type LAN 5G - Convergence sans fil et filaire 5G	- NR Sidelink relay - RAN Slicing Amélioration pour les petites données - SON / Amélioration de la minimisation des tests d'entraînement (MDT) Qualité de l'expérience NR - Évolution de l'architecture eNB, division LTE C-plane / U-plane - Composants satellites dans l'architecture 5G - Amélioration des réseaux non publics. - Automatisation des réseaux pour la 5G - phase 2 L'informatique de périphérie dans la 5GC - Services de proximité dans la 5GS - Découpage du réseau - phase 2 - Améliorer. Services V2x - Services interactifs avancés - Prise en charge de l'orientation, de la commutation et du fractionnement du trafic d'accès dans l'architecture du système 5G - Services de type LAN 5G - Amélioration de la fonction du plan d'utilisateur (UPF) pour le contrôle et l'architecture basée sur les services 5G (SBA)

Table 2 Caractéristiques de la version 17

I.4 Spectre et fréquence de la 5G

L'interface radio définie par le 3GPP pour la 5G est connue sous le nom de New Radio (NR) et est divisée en deux bandes de fréquences, FR1 (inférieure à 6 GHz) et FR2 (ondes millimétriques), chacune ayant des capacités différentes.

- **I.4.1 Gamme de fréquences 1 (inférieure à 6 GHz)**

La bande de fréquence Sub 6G est la bande de basse fréquence et la bande de fréquence primaire de la 5G. Les fréquences inférieures à 3 GHz sont appelées sub3G, et les autres bandes de fréquences sont appelées bande C [9].

En raison de la pénurie de spectre continu dans cette gamme de fréquences occupée, la largeur de bande de canal maximale définie pour FR1 est de 100 MHz. Dans cette gamme, la bande la plus souvent utilisée pour la 5G est de 3,3-4,2 GHz (bande C). Bien qu'une partie du spectre des ondes millimétriques ait été attribuée, les opérateurs coréens utilisent la bande n78 à 3,5 GHz.

Table 3 Nouvelles bandes pour l'introduction de NR (FR1)

Nouvelles bandes	Opérateurs
Bande n77 (3300-4200 MHz) Bande n78 (3300-3800 MHz)	✓ NTT DOCOMO, KDDI, Softbank Mobile, China Mobile, China ✓ Unicom, China Telecom, KT, SK Telecom, LG Uplus, Etisalat. ✓ Orange, Telecom Italia, British Telecom, Deutsche Telekom, Telstra
Bande n79 (4400-5000 MHz)	✓ NTT DOCOMO, KDDI, Softbank Mobile, China Mobile, China ✓ Unicom, China Telecom

- **I.4.2 Gamme de fréquences 2**

Les ondes millimétriques que plus de 6GHz qui est la bande de haute fréquence et est la bande de fréquence étendue de la 5G, qui est riche en ressources de spectre.

Les largeurs de bande minimale et maximale des canaux pour FR2 sont respectivement de 50 et 400 MHz, l'agrégation à deux canaux étant prise en charge dans la version 15 du 3GPP. Verizon utilise la bande n258 à 28 GHz aux États-Unis, tandis qu'AT&T utilise 39 GHz. La capacité à gérer des vitesses de transfert de données élevées est proportionnelle à la fréquence.

Nouvelles bandes	Opérateurs
Bande n257 (26,5-29,5 GHz) Bande n258 (24,25-27,5 GHz)	✓ NTT DOCOMO, KDDI, Softbank Mobile, China Mobile, KT, SK ✓ Telecom, LG Uplus, Etisalat, Orange, Verizon, T-mobile, Telecom ✓ Italia, British Telecom, Deutsche Telekom, Telstra
Bande n260 (37-40 GHz) *	✓ AT&T, Verizon, T-mobile

Table 4 Nouvelles bandes pour l'introduction de NR (FR2)

I.5 5G Applications et cas d'usage

Avec la 5G et les usages prévus qu'elle permettra, la vie va changer, mais pas de manière universelle. Parce qu'il est difficile d'installer la 5G partout à la fois, il y aura un écart croissant dans la connexion au réseau et les services entre les régions urbaines et rurales.

Le concept central de la 5G est un réseau unique qui peut prendre en charge un large éventail de cas d'utilisation divers. Pour tenir les promesses de la 5G, les opérateurs de réseaux mobiles (ORM) doivent développer un réseau dense avec un grand nombre de nœuds de réseau, qui servira d'infrastructure 5G.

Les ORM investiront dans la 5G en améliorant et en densifiant le réseau dans les villes dans un premier temps, où ils peuvent servir un grand nombre de consommateurs payants et obtenir un retour sur investissement plus rapide. La mise en œuvre de la 5G dans les régions rurales sera plus progressive [10]




Figure 1. 3 Vision de l'UIT pour IMT2020

Le "triangle 5G", comme on appelle le déploiement de la 5G, apportera des avantages dans trois domaines principaux :

- uRLLC : Cas d'utilisation de la communication ultra-fiable à faible latence
- mMTC : Cas d'utilisation de la communication massive de type machine (IoT)
- eMBB : Enhanced Mobile Broadband - cas d'utilisation à haut débit

I.5.1 cas d'utilisation innovants de la 5G

L'amélioration de la vitesse et de la cohérence de la 5G et les réductions de latence qu'elle permet devraient avoir un impact sur les industries conventionnelles et numériques. Et la technologie 5G a beaucoup de potentiel dans les mois, les années et les décennies à venir.

Les cas d'utilisation de la 5G ouvriront la voie aux voitures à conduite autonome, aux villes intelligentes, à l'automatisation des usines et à une nouvelle ère de communication d'entreprise. Selon les conclusions d'Accenture, 79 % des organisations du monde entier pensent que la 5G aurait une influence significative sur leur activité. Et 57 % des personnes interrogées pensent qu'elle sera transformatrice [11].

I.5.1.1 Smart cities



Figure 1. 4 Les opérateurs de réseau cherchent déjà à montrer ce que la 5G peut faire avec des projets tels que la ville intelligente d'Alba Iulia (crédit photo : ALBA IULIA)

Les fournisseurs de réseaux démontrent déjà ce qui peut être accompli avec la technologie 5G. L'un de ces cas d'utilisation de la 5G est la ville intelligente d'Alba Iulia, qui collabore avec Orange et comprend la surveillance du trafic, des capteurs de stationnement et une gestion intelligente des déchets dans la ville roumaine.

La 5G permettra également la mise en place d'industries intelligentes, avec notamment plus de robots dans les chaînes de fabrication et des drones pour les livraisons du dernier kilomètre. Elle permettra également la communication de voiture à voiture en cas de risques ou de mésaventures, ainsi que des véhicules entièrement autonomes.

I.5.1.2 Véhicules autonomes

L'une des applications 5G les plus attendues est la voiture autonome. Pour permettre l'avènement de la voiture autonome, la technologie automobile s'améliore rapidement. Les ordinateurs embarqués s'améliorent à tel point qu'ils peuvent désormais égaler la capacité de calcul des centres de données.



Figure 1. 5 Véhicules autonomes

Aujourd'hui, nous entendons beaucoup parler de voitures autonomes, et beaucoup de gens sont curieux de savoir quels sont les obstacles à la concrétisation de cette technologie futuriste. Pour que l'avenir des voitures entièrement autonomes devienne une réalité, plusieurs avancées distinctes dans la technologie des véhicules, la vitesse du réseau, le débit de données et l'apprentissage automatique doivent être réunies.

En raison de la réduction substantielle de la latence, les réseaux 5G seront un énorme catalyseur pour les voitures autonomes, permettant aux véhicules de répondre 10 à 100 fois plus rapidement que les réseaux cellulaires existants.

Un réseau de communication de véhicule à tout (V2X) est l'objectif ultime. Grâce à lui, les véhicules seront en mesure de réagir presque instantanément aux objets et aux modifications de leur environnement. Pour s'arrêter ou changer de direction en réaction aux panneaux de signalisation, aux dangers et aux personnes qui traversent la rue, un véhicule doit être capable de transmettre et de recevoir des informations en quelques millisecondes.

Voyons comment la latence diffère entre la 4G et la 5G : supposons qu'une automobile se déplaçant à 30 Mph ait besoin de recevoir un signal pour éviter d'entrer en collision avec quelque chose. Un véhicule se déplacerait d'environ 4 pieds ou 1,2 mètre avec une latence 4G actuelle d'environ 100 millisecondes. La voiture se serait à peine déplacée de 5 pouces (12 cm) avec un délai de dix millisecondes sur la 5G.

I.5.1.3 E-santé

Pierre angulaire des soins de santé contemporains, la 5G a le potentiel de sauver des vies. L'efficacité et l'efficience des traitements peuvent être améliorées grâce à des consultations vidéo haute résolution, des robots d'assistance et des vêtements intelligents. Notre santé est l'aspect le plus précieux de qui nous sommes et de ce que nous possédons. Les médecins peuvent aider davantage de patients en leur proposant des traitements mieux ciblés et des interventions plus rapides grâce aux technologies de soins de santé connectés [12]. La 5G gagnera en importance à mesure que les consultations vidéo, les robots médicaux et les vêtements intelligents deviendront plus courants. Les soins de santé connectés améliorent les résultats des patients. Les fournisseurs de services peuvent offrir la 5G pour permettre des cas d'utilisation tels que ceux-ci :

1. Les flux vidéo haute définition entre les ambulances et les hôpitaux reliés entre eux aident les ambulanciers à traiter les patients en transit et les hôpitaux à se préparer à leur arrivée.
2. La vidéo haute définition peut également être utilisée pour la télémédecine, permettant aux patients (notamment dans les maisons de retraite) et aux médecins de communiquer.
3. Les vêtements intelligents et les capteurs intégrés aux articulations de remplacement permettent aux cliniciens de communiquer avec les patients de manière plus approfondie et plus rapide.

I.5.1.4 Robotique et automatisation dans le nuage

Grâce à l'Edge Cloud, les robots peuvent être contrôlés et reprogrammés pour aider dans divers environnements, y compris les hôpitaux et les industries. Ils peuvent être moins compliqués maintenant que le traitement est effectué en dehors des robots [13].

À mesure que la 5G les connecte à l'intelligence du Edge Cloud, les robots gagneront en autonomie. Cela leur donnera des chances supplémentaires de réaliser des travaux dangereux et répétitifs. Les capteurs peuvent collecter des données pour générer des "jumeaux numériques", qui peuvent améliorer n'importe quel processus.

L'intelligence artificielle connaît une révolution.

Les fournisseurs de services peuvent permettre les robots du futur en fournissant des réseaux extrêmement fiables et à faible latence :

Grâce à la reconfiguration à distance des contrôleurs logiques programmables, les robots des chaînes de production peuvent effectuer de nombreuses tâches (PLC).

Les systèmes d'automatisation, qui utilisent le traitement d'images et l'apprentissage automatique sur le cloud, peuvent aider au contrôle de la qualité dans les processus industriels.

Dans les hôpitaux, les robots collaboratifs peuvent guider les patients ou administrer des médicaments, et ils peuvent être utilisés comme une flotte à partir d'un emplacement central.

Vidéosurveillance et analyse

Analytique et surveillance vidéo, La vidéo haute définition en temps réel et l'analytique pilotée par l'IA permettent de mieux appréhender les villes intelligentes, les industries et les applications environnementales. Une bande passante massive en liaison montante et une faible latence assurée sont nécessaires pour les applications vidéo en temps réel et l'analytique, et la 5G offre les deux.

La façon dont nous gouvernons le monde est en train de changer grâce à la technologie vidéo. L'analyse vidéo peut transformer les flux de caméras haute définition en informations utiles grâce à l'intelligence artificielle (IA). Avec la bande passante de liaison montante et la qualité de service dont la vidéo 4K et 8K a besoin, seule la 5G peut gérer la densité croissante de caméras. Vous pouvez également profiter de l'indépendance et de la flexibilité des communications sans fil avec la 5G.

Des caméras connectées et intelligentes

La prise en charge de nouveaux cas d'utilisation de l'analyse vidéo donne aux fournisseurs de services la possibilité de développer leur activité :

- Pour assurer le mouvement et la sécurité des villes, les applications de villes intelligentes et sûres peuvent surveiller les files d'attente et les anomalies de comportement.
- Le contrôle de la qualité et la gestion de la sécurité physique sont des exemples d'applications industrielles qui peuvent aider les fournisseurs de services à acquérir de nouveaux clients.
- Les drones équipés de caméras haute définition peuvent fournir des services de surveillance et d'inspection, la 5G permettant une entrée et un contrôle à faible latence.

Expériences immersives

La 5G va révolutionner les médias numériques en nous permettant d'entrer dans un environnement 3D haute résolution et d'éprouver un nouveau sentiment d'émerveillement. Les technologies de réalité étendue (XR), telles que la réalité virtuelle et la réalité augmentée, sont stimulées par la 5G. Les informations, les objets et les personnes seront tout autour de nous lorsque nous utiliserons ces technologies, plutôt que simplement devant nous, ce qui produira une forte implication émotionnelle.

Expériences en direct de 360-Degree

Imprégnez-vous de l'atmosphère et regardez autour de vous. Le streaming à 360 degrés vous permet de vivre des événements en direct comme si vous y étiez, en vous donnant le contrôle de ce que vous voyez. Des personnes du monde entier peuvent partager le même moment et ressentir l'excitation du déroulement des événements en temps réel. Le streaming à 360 degrés offre également un nouveau support pour la publicité, en utilisant des superpositions numériques de vidéos et d'images [14].

Des expériences étonnantes

Les revenus peuvent être augmentés en offrant des émissions immersives que les consommateurs apprécient :

- Des visites à 360 degrés des sept merveilles du monde.
- Les gens pourront regarder des concerts de n'importe où et avoir l'impression d'être dans l'arène.
- Pour offrir la meilleure expérience immersive, nous fournissons du matériel totalement immersif pour les casques de réalité virtuelle (VR).

Réalité virtuelle (RV)

La réalité virtuelle (RV) est sur le point de révolutionner la façon dont nous nous engageons avec les médias numériques et les autres. Des résolutions plus élevées rendront nos mondes virtuels plus réalistes, tandis que des réseaux plus rapides nous permettront de créer des environnements virtuels 3D partagés où nous pourrions nous rencontrer, jouer et apprendre.

Entrez dans la troisième dimension

Offrir une plateforme pour de grandes expériences de RV 3D peut aider les prestataires de services à générer des revenus supplémentaires :

- Les employeurs pourraient contribuer à l'amélioration des environnements de formation.
- Les joueurs pourraient vivre des expériences plus passionnantes et plus réalistes.
- Les amitiés et les relations familiales pourraient être ravivées, ce qui ouvrirait une nouvelle ère dans notre histoire sociale.

Réalité augmentée (RA)

Donnez à vos clients des capacités surhumaines pour voir les choses d'une nouvelle façon. La réalité augmentée (RA) améliore le monde physique en ajoutant une couche numérique à la vue de la caméra. La réalité augmentée donne aux utilisateurs l'œil d'un expert, ce qui leur permet de comprendre rapidement ce qu'ils doivent faire ensuite, qu'il s'agisse de simplifier les instructions de montage d'un meuble ou d'aider à dépanner une voiture en panne.

Découvrez la puissance de la réalité augmentée

Découvrez comment la réalité augmentée peut vous aider à atteindre vos objectifs. Les fournisseurs de services peuvent tirer profit de la mise à disposition d'une plateforme permettant le développement de nouvelles applications de réalité augmentée :

- Grâce à l'instruction en temps réel sur le lieu de travail, le coaching assisté pourrait accélérer les réparations, améliorer la qualité des activités de production manuelle et réduire le temps de formation.
- Les touristes pourraient utiliser leur téléphone pour enregistrer une critique visuelle des sites touristiques.
- En pointant leur téléphone vers la boîte sur l'étagère, les acheteurs pourraient regarder les produits en action.

I.6 5G Les défis

Les défis sont un élément inévitable de tout nouveau développement, et la 5G, comme toute autre technologie, doit faire face à des obstacles importants. Nous pouvons observer une expansion incroyablement rapide dans le

passé, par exemple, le développement de la technologie radio. Le voyage a tout juste une quarantaine d'années, commençant à 1G et se terminant à 5G. (En considérant la 1G dans les années 1980 et la 5G dans les années 2020) [15] Cependant, les défis les plus courants que nous avons rencontrés au cours de ce voyage sont le manque d'infrastructure, la méthodologie de recherche et les coûts.

Il existe deux types différents de défis liés à la 5G :

- Les défis technologiques
- Défis communs

I.6.1 Défis technologiques

I.6.1.1 Brouillage intercellulaire

C'est l'un des problèmes techniques les plus pressants. Les macrocellules traditionnelles et les petites cellules concurrentes sont de tailles différentes, ce qui entraîne des interférences.

I.6.1.2 Contrôle efficace de l'accès au support

Lorsqu'un déploiement dense de points d'accès et de terminaux d'utilisateurs est nécessaire, le débit des utilisateurs sera faible, la latence sera importante et les hotspots ne seront pas en mesure de fournir un débit élevé avec la technologie cellulaire. Il convient d'étudier en détail la possibilité d'optimiser la technologie.

I.6.1.3 Gestion du trafic

Contrairement au trafic humain traditionnel dans les réseaux cellulaires, les nombreux dispositifs Machine to Machine (M2M) dans une cellule peuvent poser de graves problèmes de système, tels que les problèmes de réseau d'accès radio (RAN), qui entraînent une surcharge et une congestion.




Figure 1. 6 Les défis technologiques de la 5G

I.6.2 Défis communs

I.6.2.1 Services multiples

La 5G devra relever un défi de taille : fournir des réseaux, des technologies et des dispositifs divers dans des lieux géographiques variés, contrairement aux services de signaux radio antérieurs. Il s'agit donc de normaliser des services sans fil dynamiques, universels, centrés sur l'utilisateur et riches en données afin de répondre aux attentes élevées de la population.

I.6.2.2 Infrastructure

La normalisation et la mise en œuvre des services 5G posent des défis technologiques aux chercheurs.

I.6.2.3 Communication, navigation et détection

La disponibilité du spectre radioélectrique, qui est utilisé pour transmettre les signaux, est essentielle pour ces services. Bien que la technologie 5G puisse analyser des quantités massives de données provenant de diverses sources, elle nécessite davantage d'infrastructures.

I.6.2.4 Sécurité et confidentialité

L'un des défis les plus importants auxquels la 5G est confrontée est de garantir la sécurité des données personnelles. La 5G devra clarifier les inconnues entourant les menaces de sécurité telles que la confiance, la vie privée et la cybersécurité, qui sont de plus en plus répandues dans le monde.

I.6.2.5 Législation du cyber droit

Avec la technologie 5G à haut débit et omniprésente, la cybercriminalité et d'autres formes de fraude peuvent apparaître. Par conséquent, la législation sur la cybercriminalité est un problème critique qui constitue une préoccupation gouvernementale et politique (nationale et internationale) de premier plan.




Figure 1. 7 Les défis de la 5G

I.7 Conclusion

La technologie 5G est plus innovante, avec la capacité de relier le globe entier sans frontières. Elle est conçue pour offrir des capacités de données inégalées, des volumes d'appels illimités et une énorme transmission de données. L'accès à la connaissance, à l'engagement et au divertissement sera universel et sans entrave à l'avenir, ouvrant et canalisant une nouvelle dimension à notre existence. En outre, les gouvernements et les autorités pourraient utiliser cette innovation pour promouvoir la bonne gouvernance et créer des environnements plus sains, encourageant ainsi la poursuite des investissements dans la technologie 5G. L'avantage le plus apparent sera la vitesse. La 5G devrait offrir des débits allant de 50 mégabits par seconde à plus d'un gigabit par seconde. Par conséquent, vous bénéficierez de vitesses similaires à celles du haut débit domestique, où que vous soyez. Lorsqu'il s'agit de télécharger des films et des fichiers volumineux, cela aura un impact considérable.

I.8 Références

- [1] “5G – Just Out Tech.” <https://justouttech.com/blog/5g/>
- [2] Amal Varghese, “Reliance Jio 5G Industry is here with an indigenous network upgrade solution - DOS2SHELL.” <http://www.dos2shell.com/reliance-jio-5g-industry-is-here/>
- [3] E. Dahlman, S. Parkvall, and J. Skold, 5G NR: The Next Generation Wireless Access Technology, 2nd edition. London San Diego, CA Cambridge, MA Oxford: Academic Press, 2020.
- [4] C. Cox, An introduction to 5G: the new radio, 5G network and beyond. Hoboken, NJ: Wiley, 2020.
- [5] “M.1034-1 - Requirements for the radio interface(s) for international mobile telecommunications-2000 (imt-2000),” p. 27.
- [6] “3GPP (2020) 3GPP: The mobile broadband standard. www.3gpp.org”.
- [7] J. Rodriguez, Ed., Fundamentals of 5G mobile networks. Chichester, West Sussex, United Kingdom; Hoboken, NJ: John Wiley & Sons Ltd, 2015.
- [8] “ITU-R M.2134 (2008) Requirements related to technical performance for IMT-Advanced radio interface”.
- [9] Huawei, Huawei Certification ICT Associate 5G. Huawei, 2019.
- [10] Harald Remmert, “5G Applications and Use Cases,” Nov. 25, 2019. <https://www.digi.com/blog/post/5g-applications-and-use-cases>
- [11] N. Brittain, “30 top 5G use cases: discover what 5G can really do | 5Gradar,” Aug. 2021. <https://www.5gradar.com/features/what-is-5g-these-use-cases-reveal-all>
- [12] Nokia, “eHealth,” Nokia. <https://www.nokia.com/networks/5g/use-cases/ehealth/>
- [13] “Cloud Robotics and Automation,” Nokia. <https://www.nokia.com/networks/5g/use-cases/cloud-robotics/>
- [14] “Immersive Experiences,” Nokia. <https://www.nokia.com/networks/5g/use-cases/immersive-experiences/>
- [15] “5G - Challenges.” https://www.tutorialspoint.com/5g/5g_challenges.htm

CHAPITRE II

*Le Big Data et L'internet des
objets IoT*

II.1 Introduction

Le Big Data est une technique qui dépasse la capacité de traitement des structures de base de données obsolètes. Les données sont excessivement volumineuses, évoluent trop rapidement et ne conviennent pas aux configurations de nos bases de données [1].

Pour valoriser ces données, il faut adopter une technique de substitution pour les traiter. Les 2,5 quintillions d'octets de données quotidiennes, soit 90 % des données de la biosphère actuelle, ont été conçus au cours des deux dernières années seulement [2].

Le big data est l'une des technologies en plein essor pour le prochain groupe d'âge des industries basées sur l'information et la communication [3], qui sont largement réalisées sur la troisième plateforme, mentionnant principalement le big data, le cloud computing, l'Internet des objets (IoT) et le commerce sociétal [4].

Il est nécessaire de qualifier la révolution des données.

Des recherches considérables ont été menées par de nombreux scientifiques sur le big data et ses tendances [5].

L'analyse des big data porte surnommé volume d'ensembles de données, comme le montre le tableau 2.1. Les données d'entrée des systèmes de big data peuvent provenir des sources suivantes [6] :

- Réseaux sociaux et de collaboration.
- Fichiers journaux du serveur web.
- Données des capteurs et données des images satellites.
- Flux audio et vidéo.
- Transactions en banque.
- Données sur le contenu des pages Web.
- Documents et dossiers gouvernementaux.
- Télémétrie des automobiles.
- Données provenant des marchés financiers.

Ce chapitre se concentre sur les concepts de base, les problèmes, les défis, les outils et les techniques, et les

applications du big data. En outre, les problèmes de recherche ouverts sont discutés.

Les avancées technologiques dans le traitement et l'analyse de ces données massives permettent aux entreprises d'extraire des informations précieuses, d'améliorer la prise de décision et d'optimiser les opérations [7].

S. Non.	Mémoire	Symboliser	Taille
1	1 Kilo-octet	KB	103
2	1 mégaoctet	MB	106
3	1 Gigaoctet	GB	109
4	1 téraoctet	TB	1012
5	1 pétaoctet	PB	1015
6	1 Exabyte	EB	1018
7	1 Zettaoctet	ZB	1021
8	1 Yottabyte	YB	1024

Table 5 Symbole et taille de la mémoire : manipulée par le big data

II.2 L'évaluation du Big Data avec ses outils

Le terme Big Data a été conçu par Roger Mougalias en 2005. Le Big Data et la quête de reconnaissance de la disponibilité des données sont des phénomènes qui ont été présents pendant une longue période. Le tableau 2.2 présente l'évolution de l'analyse des big data et le tableau 2.3 présente l'évolution des outils d'analyse des big data.

II.3 Architecture du Big Data

Le big data est un domaine qui analyse et extrait systématiquement les informations d'autres ensembles de données. La figure II.1 décrit le cadre architectural du big data.

II.3.1 Cadre de travail pour l'analyse du Big Data

- i. Sources de données massives
- ii. Stockage des données par lots

- iii. Incorporation de messages en temps réel
- iv. Traitement par lots
- v. Traitement en continu et apprentissage automatique
- vi. Magasin de données analytiques (big data)
- vii. Analyse des données massives
- viii. Reporting

S. Non.	Année	Technologie	Facteurs clés
1.	1950's	Données très complexes (Non structurées)	
2.	1970's	Techniques statistiques	
3.	1980's	Techniques d'exploration de Données	
4.	1990's	Business-Intelligence 1.0 (BI 1.0)	Systèmes d'information à l'échelle de l'entreprise
5.	2000's	Analyse d'entreprise 2.0 (BI 2.0)	Internet, systèmes basés sur le Web
6.	2010's	Analyse des données massives 3.0 (BI 3.0)	RFID, dispositifs à base de capteurs et Internet des objets

Table 6 Évolution de l'analyse du Big Data

Évolution des outils de big data			
1.	2003	Système de fichiers Google	Lot
2.	2004	MapReduce - Traitement simplifié d'un grand cluster	
3.	2005	Doug Cutting commence à développer Hadoop	
4.	2006	Yahoo commence à travailler sur Hadoop	
5.	2008	Hadoop entre en production	
6.	2009	Yahoo crée un cochon Facebook crée Hive	
7.	2010	Yahoo crée S4 Cloudera crée Flume	
8.	2011	Nathan Marz crée Strom Spark est	
		libéré	
9.	2012	LinkedIn crée la kafka Nathan Marz définit l'architecture lambda	Temps réel
10.	2013	LinkedIn crée Samza Démarrer Lambdooop et Summingbird	
11.	2014	Stratosphere fait évoluer Flink Jay kreps définit l'architecture kappa	Hybride
12	2015	Kudu est publié par Cloudera	
13	2016	Google crée Beam	

Table 7 Évolution des outils d'analyse du Big Data




Figure 2. 1 Architecture du Big Data

II.4 Enjeux et défis

La croissance rapide des données volumineuses a engendré de nouveaux problèmes et défis dans la gestion et la recherche de données. Trois questions essentielles sont le volume, la variété et la vélocité. Dans cette section, les 10 V du big data ont été discutés. Chaque V caractérise un problème vital de la recherche technique qui nécessite un débat. Le tableau 2.4 énumère les 10 V du big data.

Les 10 V importants du big data sont représentés dans la figure 2.2, qui symbolise clairement les avantages de l'analyse des big data. Les caractéristiques du big data [8] sont classées en trois V et sont expliquées ci-dessous.

II.4.1 Volume

Le volume de données énormes fait référence à l'énorme quantité de données générées chaque seconde par un univers numérique. Tous les appareils sont connectés à des capteurs qui produisent un énorme volume de données chaque seconde. Dans le cas des soins de santé, environ 2,5 milliards de téraoctets de données sont générés chaque année ; les raffineries de pétrole génèrent également d'énormes quantités de données grâce aux capteurs qui leur sont connectés [9]. Ces volumes massifs de données, lorsqu'ils sont analysés correctement, peuvent fournir des informations précieuses qui aident à prendre des décisions éclairées et à améliorer l'efficacité opérationnelle dans divers secteurs.

S. Non.	10 V	Signification
1	Volume	Volume énorme de données circulant en temps réel
2	Variété	Ensemble de données de texte, données d'images, données de musique, données de vidéos, données graphiques.
3	Vélocité	Rapidité de déplacement des données à partir de plusieurs bases
4	Véracité	Réception de données fiables en provenance de plusieurs endroits
5	Validité	Stockage des données en termes d'authenticité et d'étapes dans le temps
6	Valeur	Valeur de l'ensemble des données conservées et calcul du sérieux.
7	Variabilité	Modification de l'ensemble de données avec le flux de données
8	Lieu	Stockage et récupération de l'ensemble des données
9	Vocabulaire	Compacité et compréhension linguistiques
10	Vague	Ensemble de données non structuré

Table 8 Les 10 V du big data détaillées




Figure 2. 2 Les 10 V du big data

II.5 Outils d'analyse du Big Data

De nombreux outils analytiques sont disponibles pour traiter les big data. Nous présentons ici quelques méthodes actuelles d'examen des big data en mettant l'accent sur les outils les plus évolutifs. De nombreux chercheurs ont proposé une excellente liste d'outils et de techniques de big data [10]. Le *tableau 2.5* énumère les outils de big data.

S. Non.	Nom de l'outil Big Data	S. Non.	Nom de l'outil Big Data
1	Apache Hadoop 	9	Tempête 
2	CDH (Distribution Cloudera pour Hadoop) 	10	Apache SAMOA 
3	Cassandra 	11	Talend 


4	Knime 	12	Rapidminer 
5	Datawrapper 	13	Qubole 
6	MongoDB 	14	Tableau 
7	Lumify 	15	
8	HPCC 		

Table 9 Outils de big data

II.6 Cas d'utilisation du big data

- Banque et finance
- Détection des fraudes
- Division client et marketing personnalisé
- Support client
- Gestion des risques
- Prévion de la valeur de la durée de vie

- Analyse de la cybersécurité
- Secteur des assurances
- Secteur des soins de santé
- Internet des objets
- Prévisions météorologiques
- Télécom

II.6.1 Banque et finance

Les secteurs des services bancaires et financiers ont été modifiés proportionnellement après le développement de l'analyse des données massives. L'amélioration de l'inspection de la régularité combinée à de plus grandes perspectives de clients a posé des expériences plus sévères et de nouveaux travaux de recherche à ces entreprises. Pour y parvenir, les organisations de services bancaires et financiers utilisent des outils de big data pour améliorer leurs services et la satisfaction de leurs clients grâce aux solutions suivantes [11].

- Solutions personnalisées
- Détection des fraudes
- Gestion des risques
- Services à la clientèle

II.6.2 Détection des fraudes

Les ensembles de données communautaires, tels que les données fournies et les programmeurs pour les processus de soins de santé, sont combinés et traités sur le big data. Ces données traitées et analysées ont subi une énorme dénormalisation pour répartir les données dans de nombreux tableaux et champs. La *figure 2.3* illustre la détection de la fraude à l'aide du big data [12]. L'analyse de ces données permet non seulement d'identifier des schémas suspects, mais aussi d'anticiper les comportements frauduleux potentiels avant qu'ils ne se produisent.

II.6.3 Division client et marketing personnalisé

Dans toute entreprise, la division client implique un groupe de personnes ou une organisation pour gérer les plaintes et les commentaires des clients et les réponses et pour obtenir plus d'informations sur leurs besoins. La division consiste plutôt à confier certaines responsabilités à un groupe de personnes en fonction de leurs qualifications et de leurs capacités. La figure 2.4 illustre la répartition des clients à l'aide du big data [13].




Figure 2. 3 Détection des fraudes à l'aide du big data

II.6.4 Support client

Voici quelques-unes des façons dont le big data permet de révolutionner le service à la clientèle.

1. Accès aux ressources disponibles
2. Accessibilité à l'assistance
3. Amélioration du temps de réponse
4. Réactivité et sympathie
5. Anticiper les besoins du client
6. Augmenter l'efficacité de la résolution des problèmes
7. Un support client personnalisé

Le Big Data pour le support client peut se faire de différentes manières, telles que l'analyste, les opérations marketing, le support analytique du chef de produit, les opérations de vente, le support des développeurs, le support des analystes opérationnels, le support des produits, le support des utilisateurs professionnels et le support des architectes de données [14]. L'intégration de ces éléments permet non seulement d'améliorer l'expérience client, mais aussi de renforcer la fidélité à la marque et d'optimiser les performances commerciales.

En exploitant efficacement le Big Data, les entreprises peuvent également identifier des tendances émergentes et anticiper les comportements futurs des clients, ce qui leur permet de s'adapter rapidement aux besoins changeants du marché.

II.6.5 Gestion des risques

La *figure II.4* illustre la gestion des risques à l'aide du Big Data. Le big data aide les entreprises à gérer les risques suivants.

- Détection et gestion des fraudes
- Gestion du crédit
- Détection et gestion des cas de blanchiment d'argent
- Prêts de marché et prêts commerciaux
- Gestion du risque opérationnel
- Gestion intégrée des risques

La collecte et l'analyse des données massives permettent de détecter les anomalies, d'évaluer la probabilité d'événements indésirables et de mettre en place des stratégies proactives pour atténuer ces risques.



Figure 2. 4 Analyse et gestion des risques à l'aide du big data

II.6.6 Prédiction de la valeur du temps de vie

Il faut identifier ces modèles de comportement, les segmenter et agir en conséquence. Le calcul de la valeur du temps de vie est très facile. Elle peut être sélectionnée pour une durée de 12 mois et de 24 mois où elle peut être utilisée en utilisant la formule optée.

$$\text{Valeur de la durée de vie} = \text{Revenu brut total} - \text{Coût total}$$

- Choses à faire pour la prédiction de la valeur du temps de vie
- Définir le délai approprié pour le calcul de la valeur de la durée de vie du client
- Cochez si c'est utile

- Construire et exécuter des modèles d'apprentissage automatique pour la prédiction de la valeur de la vie [15].

II.6.7 Analyse de la cybersécurité

Les cas d'utilisation des big data ont donné lieu à de nombreuses procédures de sécurité, telles que la mise à l'échelle des réseaux, les dispositifs portables, les services bancaires mobiles, le transfert électronique de fonds, l'échange électronique de données, la surveillance de la sécurité [16] et l'absence d'intrusion [17]. En matière de cybersécurité, les techniques de big data trouvent une application de la manière suivante.

- Analyse des vulnérabilités des grands réseaux
- Aide à la recherche efficace d'informations. Les "fichiers de suivi" sont des fichiers très volumineux contenant des milliards de mots de passe qui peuvent être utilisés pour tester la sécurité du système.
- L'utilisation du cloud pour mieux aider le forçage brut en réduisant le temps nécessaire.
- Utilisation du réseau naturel pour analyser le système, comme le réseau et les bases de données, afin de détecter les vulnérabilités.

II.6.8 Secteur des assurances

L'analyse des big data est une nouvelle technologie qui aide les compagnies d'assurance à gérer les situations difficiles et à prendre des décisions rationnelles en leur fournissant des informations intuitives sur les big data disponibles. Les cas d'utilisation du big data dans le secteur de l'assurance représentent ce qu'une entreprise peut résoudre, grâce à des informations précises. La *figure 2.5* illustre la gestion du secteur des assurances à l'aide des big data [18].

Rôle du Big Data dans le secteur des assurances

- Acquisition de clients
- Fidélisation des clients
- Évaluation des risques
- Détection et gestion des fraudes
- Réduction des coûts




Figure 2. 5 Manipulation du secteur des assurances à l'aide du big data

II.6.9 Secteur de la santé

Le big data des soins de santé désigne la collecte, l'examen et l'exploitation des données de diagnostic médical des patients, qui sont énormes ou difficiles à reconnaître par les moyens traditionnels de traitement statistique [19]. L'analyse des données volumineuses est généralement traitée par des algorithmes d'apprentissage automatique et par la sécurité des données. De nombreuses recherches ont été menées par les chercheurs pour résoudre les problèmes auxquels le secteur de la santé est confronté [20, 21].

Les médecins s'appuient sur les dossiers médicaux des patients, ce qui représente une énorme quantité de données à l'heure actuelle et leur traitement à l'aide des anciennes techniques est très fastidieux, lent et inefficace.

- Des dossiers des patients aux systèmes de facturation, il existe certainement une grande variété de données, d'où la nécessité de recourir au big data pour résoudre ce problème.
- Le véritable défi est de savoir comment traiter et analyser une telle quantité de données pour prévoir les résultats et prendre des décisions. Il est nécessaire de développer une nouvelle infrastructure capable d'intégrer cette grande variété de données.

Exemples d'analyse du Big Data dans le secteur de la santé

1. L'analyse prédictive dans les soins de santé
2. Dossiers de santé électroniques
3. Suivi en temps réel
4. Prévention des erreurs lié à un mauvais diagnostique
5. Aide à la décision

Cette méthode est très présente dans les sociétés de soins de santé et est utilisée pour atteindre les objectifs :

- Défis et problèmes de santé des patients et de toutes les personnes malades
- Détection des fraudes et gestion efficace de celles-ci
- Diagnostic médical et traitement des patients à l'aide d'un système d'assistance clinique
- Recherche et développement efficaces et utilisation des médicaments
- Introduction de nouveaux traitements pour des maladies comme le cancer, le diabète...
- Analyse des produits avant leur commercialisation

II.6.9.1 Big Data – Aide à la décision médicale

Le système d'aide à la décision médicale (MDSS) est un domaine vital qui se fait via l'analyse des données massives et les objectifs sont fixés par les experts pour augmenter les services de soins de santé des patients en améliorant les résultats [22]. L'objectif principal de ce système MDSS est de proposer des informations valables aux patients et à leurs proches au bon moment [23]. Il aide les médecins, les pharmaciens et les patients à

prendre connaissance de l'information contenue dans toute donnée médicale spécifique [24].

II.6.9.2 Gestion des troubles basée sur le Big Data

Il aide à analyser les différents troubles et leur origine en utilisant l'examen clinique. Elle aide à trouver des informations précises en permettant de déterminer les résultats des troubles des patients le cas des TSA. Cela implique le soutien des données de plusieurs groupes comme la base des données ABIDE, des dépôts thérapeutiques et des personnes [25]. L'utilisation de ces ressources permet d'améliorer la compréhension des troubles comme les troubles du spectre autistique et de développer des approches thérapeutiques plus ciblées, favorisant ainsi une meilleure qualité de vie pour les patients concernés.

II.6.1.1 Surveillance et contrôle des patients basés sur le big data

L'utilisation de l'analytique prescriptive dans les clarifications du big data permet de lancer une méthode centrée sur le patient. Le domaine de l'ingénierie de l'information et de la communication aide à trouver les ensembles de données antérieurs sur les troubles et leur système de gestion, grâce auxquels le trouble du patient peut être soigné en connaissant les indications du trouble au lieu d'une conclusion générique sur le trouble [26].

II.6.1.2 Analyse de la routine humaine basée sur le Big Data

Cette approche vise à offrir des solutions optimales en fonction des nombreux moyens et des différents modes de vie des êtres humains. Aujourd'hui, l'identification des différentes causes des problèmes et troubles liés à la santé et le mode de vie d'un être humain joue un rôle primordial. Cela permet d'étudier les impacts et les causes de la routine humaine [27].

II.6.2 Internet des objets IoT

L'analyse des big data offre une grande variété de supports pour les applications basées sur l'IoT, de nombreuses recherches ont été menées sur les nouvelles technologies liées à l'IoT [28] utilisant les big data, à savoir les téléphones intelligents, les véhicules intelligents, l'éclairage intelligent de la maison, la maison intelligente, le lecteur de musique intelligent, la cuisine intelligente, la poubelle intelligente, la gestion intelligente des toilettes, l'agriculture intelligente, l'élevage intelligent du bétail, la pisciculture intelligente, les services intelligents, etc.

II.7 La rencontre entre l'IoT et le Big Data

Les données générées par les appareils ou les capteurs IoT nécessitent une plateforme de big data pour collecter les données historiques et actuelles, découvrir les informations à l'aide d'outils de big data et construire un modèle d'apprentissage automatique pour prédire la santé des appareils ou appliquer les données à tous cas d'utilisation spécifique à l'industrie mentionné dans la section ci-dessus [29]. Ces synergies entre l'IoT et le Big Data permettent non seulement d'améliorer l'efficacité opérationnelle, mais aussi de créer des opportunités innovantes pour la prise de décision basée sur des données en temps réel.

II.7.1 Plate-forme IoT

Le schéma ci-dessous décrit les composants nécessaires à la mise en place d'une plateforme IoT et la communication entre les différents composants. Le rôle de la périphérie de l'IoT et de la plateforme en nuage [30] qui contrôle les dispositifs IoT, les capteurs et la passerelle est également expliqué ci-dessous. La figure II.6 illustre les composants et la topologie de l'IoT.




Figure 2. 6 Architecture IoT

Précisons le rôle des différents processus présentés sur ce schéma :

- **Capter** désigne l'action de transformer une grandeur physique analogique en un signal numérique.
- **Concentrer** permet d'interfacer un réseau spécialisé d'objet à un réseau IP standard (e.g. WiFi) ou des dispositifs grand public.
- **Stocker** qualifie le fait d'agréger des données brutes, produites en temps réel, métas tagués, arrivant de façon non prédictible.
- Enfin, **présenter** indique la capacité de restituer les informations de façon compréhensible par l'Homme, tout en lui offrant un moyen d'agir et/ou d'interagir.

Deux autres processus n'apparaissent pas sur le schéma, car ils sont à la fois transverses et omniprésents :

Le **traitement des données** est un processus qui peut intervenir à tous les niveaux de la chaîne, depuis la capture de l'information jusqu'à sa restitution. Une stratégie pertinente, et commune quand on parle d'Internet des objets, consiste à stocker l'information dans sa forme intégrale. On collecte de manière exhaustive,

« big data », sans préjuger des traitements qu'on fera subir aux données. Cette stratégie est possible aujourd'hui grâce à des architectures distribuées type NoSQL, capables d'emmagasiner de grandes quantités d'information tout en offrant la possibilité de réaliser des traitements complexes en leur sein (Map/Reduce par exemple) [31].

La **transmission des données** est un processus qui intervient à tous les niveaux de la chaîne. Deux réseaux, supports des transmissions, cohabitent généralement [32] :

- **Réseau local de concentration.** On utilise alors des technologies comme ANT, ZigBee, Z-wave, NFC ou Bluetooth LE.
- **Réseau WAN**, permettant d'interconnecter les réseaux spécialisés et de les interfacer avec des fermes de serveur. On utilise alors WiFi, les réseaux cellulaires (GSM, UMTS, LTE), le réseau **LoraWan** ou encore les connexions physiques standard (Ethernet, fibre optique). Ces réseaux sont généralement connectés à Internet.

Les technologies de transmission utilisées dépendent essentiellement de l'application et du contexte. La transmission peut par exemple exploiter le Push reposant sur Comet ou WebSocket. Les canaux peuvent être bidirectionnels si l'application autorise une rétroaction. Dans certains cas, ces canaux devront transmettre les données en temps réel, dans d'autres cas, le temps ne sera pas un facteur déterminant.

Des objets, consiste à stocker l'information dans sa forme intégrale. On collecte de manière exhaustive, « big data », sans préjuger des traitements qu'on fera subir aux données. Cette stratégie est possible aujourd'hui grâce à des architectures distribuées type NoSQL, capables d'emmagasiner de grandes quantités d'information tout en offrant la possibilité de réaliser des traitements complexes en leur sein (Map/Reduce par exemple) [31].

La **transmission des données** est un processus qui intervient à tous les niveaux de la chaîne. Deux réseaux, supports des transmissions, cohabitent généralement [32] :

- **Réseau local de concentration.** On utilise alors des technologies comme ANT, ZigBee, Z-wave, NFC ou Bluetooth LE.
- **Réseau WAN**, permettant d'interconnecter les réseaux spécialisés et de les interfacer avec des fermes de serveur. On utilise alors WiFi, les réseaux cellulaires (GSM, UMTS, LTE), le réseau **LoraWan** ou encore les connexions physiques standard (Ethernet, fibre optique). Ces réseaux sont généralement connectés à Internet.

Les technologies de transmission utilisées dépendent essentiellement de l'application et du contexte. La transmission peut par exemple exploiter le Push reposant sur Comet ou WebSocket. Les canaux peuvent être bidirectionnels si l'application autorise une rétroaction. Dans certains cas, ces canaux devront transmettre les données en temps réel, dans d'autres cas, le temps ne sera pas un facteur déterminant.

II.8 Rôle de l'apprentissage automatique pour le Big Data et l'IoT

L'apprentissage automatique est une méthode d'analyse des données qui automatise la construction de modèles dans une plateforme à l'aide d'algorithmes et de procédures mathématiques. Selon le type de données (par exemple, des ensembles de données en continu comme l'audio, la vidéo, des ensembles de données basés sur des événements comme la température, l'humidité, les compteurs, etc.), le modèle analytique doit être construit et entraîné avec des attributs préétablis (par exemple, des modèles de classification comme Naïve Bayes, l'arbre de décision, etc.) ou des attributs inconnus à découvrir (par exemple, des techniques de clustering - K means clustering, DB Scan, etc.) [33] Le jeu de données disponible soit dans l'IoT edge soit dans la plateforme big data doit subir les étapes suivantes avant que nous construisions un modèle d'apprentissage automatique [34].

Ces étapes comprennent la collecte et le nettoyage des données, l'exploration pour identifier les tendances et les anomalies, ainsi que la préparation des données en normalisant ou en transformant les attributs afin d'assurer une performance optimale du modèle.

- a. Définition d'un problème commercial ou d'une étude de cas à résoudre

- b. Identifier les sources de données (par exemple, IoT Edge ou Data Lake) où nous devons obtenir les données pour construire le modèle.
- c. Sélectionnez les bonnes données à partir de l'ensemble de données collectées et nettoyez les données pour supprimer les erreurs ou les anomalies.
- d. Transformer les données [agrégats (SUM, AVG, MIN, MAX, etc.)] en fonction du niveau de granularité recherché pour construire le modèle et découvrir les modèles de données. Analyser les données à l'aide d'outils tels que le diagramme de dispersion, le graphique à barres, et interpréter le modèle de données et construire les règles (par exemple, l'analyse d'association, la matrice de dépendance, etc.)
- e. Construire le modèle en utilisant les modèles interprétés.
- f. Valider et former le modèle, le tester avec les données formées et automatiser l'apprentissage du modèle.

II.8.1 Cas d'utilisation typiques de l'apprentissage automatique

- a. Classification et détection des TSA pour une thérapie précoce et efficace.
 - a.1 Rôle de l'IoT : la collection des données comme les vidéos en temps réel.
 - a.2 Rôle du Big Data : il ingère continuellement les données dans la plateforme, qui a besoin d'un apprentissage constant du modèle que nous avons construit pour détecter l'autisme.
 - a.3 Rôle de l'apprentissage automatique : construction d'un modèle et l'entraînement après le traitement des Big Data spécifique à notre étude.
- b. Protection de la sécurité publique :

Les grandes villes ont besoin d'une surveillance constante de la sécurité publique dans les zones de criminalité ou les zones à faible sécurité. Les données provenant des caméras de vidéosurveillance et des dispositifs WiFi publics installés par la ville doivent être analysées et un modèle d'analyse vidéo doit être construit pour trouver les intrus ou les délinquants qui errent dans cette zone. Cela aidera le département de la sécurité publique à envoyer des alertes aux agents de la police municipale qui patrouillent ou à envoyer les alertes avec les images à la salle de contrôle qui surveille cette zone ou ce secteur particulier.

b.1 Rôle de l'IoT : Les caméras de vidéosurveillance et le WiFi public sont les deux sources de données de l'IoT qui diffusent en continu les données à la passerelle IoT. Le WiFi public permet d'obtenir les détails des personnes qui se trouvent dans la rue et qui ont enregistré le WiFi

pour y accéder via leurs appareils mobiles.

b.2 Rôle du Big Data : les plateformes de Big Data comme Hadoop doivent stocker de gros fichiers de données non structurés de CCTV (fichiers vidéo).

Le moteur de traitement, comme Spark ou MapReduce, doit traiter ces gros fichiers en petits morceaux (par exemple, des images ou des cadres de l'ensemble des données vidéo) et étiqueter l'image avec un horodatage correct et des détails de localisation géographique [35]. Les données doivent être récupérées rapidement à l'aide de Hadoop ou MapReduce. La plateforme Big Data prend en charge le cadre d'apprentissage automatique ou profond (soit Mahout, soit Pytorch, soit Keras soit Tensorflow) pour construire un modèle qui nécessite un apprentissage continu pour découvrir l'intégrité des données et éliminer les enregistrements anormaux.

L'utilisation de techniques d'apprentissage automatique permettra non seulement d'améliorer la précision des analyses, mais également d'optimiser le traitement en temps réel des flux vidéo pour détecter des événements ou comportements suspects.

b.3 Rôle de l'apprentissage automatique : Les cadres d'apprentissage automatique ou d'apprentissage profond doivent être évalués pour la détection et la reconnaissance des objets. Les métadonnées de l'image sont essentielles pour les mélanger avec l'ensemble des données collectées par la vidéosurveillance et détecter les intrus ou les délinquants avec précision. L'analyse des journaux doit également être développée pour identifier les anomalies et extraire les informations sur les personnes, les relier aux images de vidéosurveillance pour un meilleur étiquetage et créer des alertes basées sur ces informations.

II.9 Conclusion

Le big data est un sujet très vaste qui se développe rapidement. Bien qu'il ne soit pas adapté à tous les types d'informatique, plusieurs établissements se tournent vers le big data pour des catégories de missions convaincantes et l'utilisent pour compléter leurs outils d'investigation et d'entreprise actuels. Les systèmes de big data sont exclusivement adaptés à la mise au point de concepts difficiles à détecter et à la fourniture d'informations de manière intolérable à la découverte par des moyens orthodoxes. En mettant correctement en œuvre des systèmes qui s'accordent avec le big data, l'IoT et l'apprentissage automatique, les établissements peuvent tirer parti de la valeur incroyable des données qui sont auparavant offertes. Il sera évident que le big data récoltera les bénéfices en fonction des cas d'affaires que nous avons identifiés pour un domaine spécifique.

II.10 Références

- [1] S. Chaudhary, “Analysis of Concept of Big Data Process, Strategies, Adoption and Implementation,” *International journal on future revolution in computer science & communication engineering*, Mar. 2022, doi: 10.17762/ijfrcsce.v8i1.2065. E. Conti et al., “Autism Spectrum Disorder and Childhood Apraxia of Speech: Early Language-Related Hallmarks across Structural MRI Study,” 2020. doi: 10.3390/JPM10040275.
- [2] N. Lekic, S. Djukanovic, M. Bajceta, and T. Savic, “A bioinformatic system for collecting and processing environmental data,” in *Telecommunications Forum*, Nov. 2015. doi: 10.1109/TELFOR.2015.7377546.
- [3] S. Xue-qin, “Big Data: a Revolution in Information Technology and Information Management,” *Information Sciences*, Jan. 2014.
- [4] B. J. Durkin, I. Lokshina, and C. J. M. Lanting, “Data Analysis Services Related to the IoT and Big Data: Potential Business Opportunities for Third Parties,” in *Hawaii International Conference on System Sciences*, Jan. 2017. doi: 10.24251/HICSS.2017.533.
- [5] G. Rieder and J. Simon, “Big Data: A New Empiricism and its Epistemic and Socio-Political Consequences,” 2017. doi: 10.1007/978-3-658-12153-2_4.
- [6] F. Arena and G. Pau, “An overview of big data analysis,” *Bulletin of Electrical Engineering and Informatics*, Aug. 2020, doi: 10.11591/EEI.V9I4.2359.
- [7] H. Alsghaier, M. Akour, I. Shehabat, and S. Aldiabat, “The Importance of Big Data Analytics in Business: A Case Study,” Sep. 2017, doi: 10.11648/J.AJSEA.20170604.12.
- [8] N. Khan, M. Alsaqer, H. Shah, G. Badsha, A. A. Abbasi, and S. Salehian, “The 10 Vs, Issues and Challenges of Big Data,” in *International Conference on Big Data*, Mar. 2018. doi: 10.1145/3206157.3206166.
- [9] S. Parise, “Big data: A revolution that will transform how we live, work, and think,” *Journal of information technology case and application research*, Sep. 2016, doi: 10.1080/15228053.2016.1220197.
- [10] R. Dautov and S. Distefano, “Quantifying volume, velocity, and variety to support (Big) data-intensive application development,” in *International Conference on Big Data*, Dec. 2017. doi: 10.1109/BIGDATA.2017.8258252.
- [11] M. Sazu and S. Jahan, “How Big Data Analytics is transforming the finance industry,” *Bankarstvo*, Jan. 2022, doi: 10.5937/bankarstvo2202147h.
- [12] M. Herland, T. M. Khoshgoftaar, and R. A. Bauder, “Big Data fraud detection using multiple medicare data sources,” *Journal of Big Data*, Sep. 2018, doi: 10.1186/S40537-018-0138-3.
- [13] O. S. Jin, “A Customized Campaign Management System And Method Using customer segmentation,” May 20, 2020.
- [14] L. Satish and N. Yusof, “A Review: Big Data Analytics for enhanced Customer Experiences with

- Crowd Sourcing,” *Procedia Computer Science*, Jan. 2017, doi: 10.1016/J.PROCS.2017.10.058.
- [15] “Customer Lifetime Value Prediction of an Insurance Company using Regression Models,” Jan. 2023. doi: 10.1109/iconat57137.2023.10080805.
- [16] “An Overview on Emerging Security Threats in Big Data Clusters and their Defenses,” in *2022 International Conference on Edge Computing and Applications (ICECAA)*, Oct. 2022. doi: 10.1109/icecaa55415.2022.9936513.
- [17] “Integrated Security Systems using Big Data,” in *2022 International Conference on Inventive Computation Technologies (ICICT)*, Jul. 2022. doi: 10.1109/iciict54344.2022.9850884.
- [18] D. Szaniewski, “Big data analytics in insurance,” 2023. doi: 10.4324/9781003310082-16.
- [19] S. N. Musy, S. N. Musy, M. Simon, and M. Simon, “Big Data in Healthcare: New Methods of Analysis,” 2017. doi: 10.1007/978-3-319-53300-1_5.
- [20] M. J. Milenković, A. Vukmirovic, and D. Milenkovic, “Big data analytics in the health sector: challenges and potentials,” Jan. 2019, doi: 10.7595/MANAGEMENT.FON.2019.0001.
- [21] K. Slime, A. Maizate, and L. Hassouni, “Processing and Analyzing Health Data in a Big Data Context: Aspects and Implementations,” 2019. doi: 10.1007/978-3-030-36664-3_34.
- [22] A. Dagliati *et al.*, “Big Data as a Driver for Clinical Decision Support Systems: A Learning Health Systems Perspective,” May 2018, doi: 10.3389/FDIGH.2018.00008.
- [23] A. Romanychev and V. Bobkov, “System and method for communicating medical data,” Dec. 10, 2020.
- [24] I. Hoffmann, M. Behrends, H. Consortium, and M. Marschollek, “Data Literacy in Medical Education - An Expedition into the World of Medical Data,” in *International Conference on Informatics, Management and Technology in Healthcare*, Jun. 2022. doi: 10.3233/SHTI220711.
- [25] F. Qureshi and J. Hahn, “Towards the Development of a Diagnostic Test for Autism Spectrum Disorder: Big Data Meets Metabolomics,” *Canadian Journal of Chemical Engineering*, Aug. 2022, doi: 10.1002/cjce.24594.
- [26] “Descriptive, Predictive, and Prescriptive Analytics in Healthcare,” 2022. doi: 10.1201/9781003215981-9.
- [27] S. T. Castro, K. A. Salcido, and L. G. Rodríguez, “Proposal of a New Descriptive-Correlational Model of Population Lifestyle Analysis and Disease Diagnosis,” *Advances in Science, Technology and Engineering Systems Journal*, Nov. 2020, doi: 10.25046/AJ050667.
- [28] A. F. Ahmad, Md. S. Sayeed, C. P. Tan, K. G. Tan, A. Bari, and F. Hossain, “A Review on IoT with Big Data Analytics,” in *International Conference on Information and Communication Technology*, Aug. 2021. doi: 10.1109/ICOICT52021.2021.9527503.
- [29] L. T. Yang, “A Data-as-a-Service framework for IoT big data,” in *International Conference on Security and Cryptography*, Jul. 2013.
- [30] “IoT Platform: Technology, Use Cases, and Standardization,” Oct. 2022. doi: 10.1109/wf-

iot54382.2022.10152042.

- [31] J. Zhao and Y. Shen, “Data processing method in Internet of Things,” Aug. 09, 2019
- [32] W. Zhao *et al.*, “Data transmission method and system,” Jan. 26, 2021
- [33] “Machine learning for intelligent analytics,” 2022. doi: 10.1201/9781003269144-13.
- [34] H. Jamil, T. Umer, C. Ceken, and F. Al-Turjman, “Decision Based Model for Real-Time IoT Analysis Using Big Data and Machine Learning,” *Wireless Personal Communications*, Aug. 2021, doi: 10.1007/S11277-021-08857-7.
- [35] Z. Sun, F. Chen, M. Chi, and Y. Zhu, “A Spark-Based Big Data Platform for Massive Remote Sensing Data Processing,” 2015. doi: 10.1007/978-3-319-24474-7_17.

CHAPITRE III

*Classification de l'autisme
par l'apprentissage profond*

III.1 Introduction

Dans ce chapitre, tous les concepts théoriques pertinents pour la recherche dans cette thèse sont discutés. Les troubles du spectre autistique (TSA) sont des troubles neurodéveloppementaux caractérisés par des déficits de communication sociale, tels qu'une réduction du contact visuel et des troubles de la parole. L'imagerie par résonance magnétique (IRM) a été utilisée pour détecter des anomalies dans la structure cérébrale des patients atteints de TSA, telles que la réduction du volume de l'amygdale [1]. Certains travaux antérieurs ont établi la corrélation entre les données de l'IRM et le développement de la parole au niveau phonologique [2]. D'autres travaux ont utilisé du texte provenant de transcriptions ou d'annotations audio manuelles pour valider la neuroprédiction [3]. Cependant, aucune recherche existante ne présente d'expériences utilisant les données de l'IRM pour classifier les TSA. L'occasion se présente lorsque plus de 1000 échantillons de données d'IRM avec des étiquettes de TSA sont fournis sur la base des données ABIDE [4]. Nous pouvons appliquer des modèles CNN pour prédire diverses caractéristiques à partir des données d'IRM. En utilisant l'un des plus grands ensembles de données, ces expériences pourraient fournir des résultats précieux sur la neuroprédiction non invasive des caractéristiques linguistiques des TSA. De tels modèles pourraient être utilisés dans le monde réel pour faciliter le diagnostic des TSA, en particulier chez les jeunes patients, les patients non verbaux ou dans les zones rurales. Nous partons Du CNN pour aller vers les domaines complexes : de l'image au texte, à la traduction, au résumé et aux systèmes de dialogue. Tous ces éléments nous amènent à nous poser la question suivante : Comment la puissance des modèles avancés peut-elle être utilisée dans la recherche sur la parole dans les TSA ?

III.2 Historique des troubles du spectre autistique (TSA)

Les troubles du spectre autistique (TSA) se caractérisent par des déficits de communication sociale et des comportements non sociaux, restreints et répétitifs. Les déficits du langage, le groupe de résultats le plus cohérent, en particulier les anomalies des aspects sociaux et pragmatiques du langage, sont associés aux TSA. Malgré une relation claire, les études ont montré que les enfants atteints de TSA parlaient moins que les enfants au développement normal [5].

Au fur et à mesure que les enfants se développent, on observe la même rareté du langage parlé. La précocité de l'apparition des TSA est une caractéristique fondamentale et évidente de ces troubles [5].

C'est au cours des premières années de la vie des enfants que l'on observe les principales anomalies de développement du trouble. C'est la base du diagnostic de l'autisme à un âge précoce [6].

Des études ont montré des anomalies dans les vocalisations de l'enfant en termes de nombre, de durée, de hauteur,

de périodicité, d'échelles de temps de cohérence de la fréquence de modulation basée sur les ondelettes, de vocalisation et de synchronisation des tours de parole entre l'enfant et le parent au cours des deux premières années de vie des enfants autistes [7].

En outre, d'autres types d'atypisme peuvent être perçus par des personnes non expertes. Chez les jeunes enfants atteints de TSA âgés de 12 mois, les parents et les enfants au développement normal remarquent des atypies vocales auditives. La perception de ces personnes non professionnelles complète les anomalies acoustiques réelles chez les enfants, et leur corrélation positive avec l'un des instruments d'évaluation conventionnels est très faible. Les conclusions des chercheurs révèlent que la parole ordinaire entre les enfants autistes et les enfants au développement typique est associée à d'importantes différences acoustiques. Chez les enfants autistes, cette étude jette les bases de futures recherches qui déboucheront sur un outil de dépistage précoce des TSA [8].

L'identification précoce des TSA garantit un début de traitement plus rapide. Avec un résultat potentiellement plus favorable, une intervention précoce telle que l'ABA (Applied Behaviour Analysis) sera mise en place. Alors que le zénith de la plasticité neuronale pendant le développement éducatif précoce commence à diminuer en ce qui concerne la compétence et la latence cérébrale à l'âge de six ans [9], le dépistage et la détection précoce des TSA sont particulièrement importants pour une intervention et une thérapie précoce et c'est l'objectif de cette recherche.

III.3 L'apprentissage profond dans la recherche en neuro-imagerie

Cette section traite de l'intérêt récemment développé pour les méthodes d'apprentissage profond dans la recherche en neuro-imagerie. Pour ce faire, les développements et les changements de méthodologie dans le domaine de la recherche en neuro-imagerie seront discutés en quatre étapes.

- **III.3.1 Méthodes traditionnelles**

Au cours des deux dernières décennies, les études de neuro-imagerie par IRM des patients psychiatriques et neurologiques se sont largement appuyées sur des techniques analytiques qui comparent généralement les patients atteints d'une diagnosis d'intérêt à des individus indemnes de la maladie, en rapportant les différences neuroanatomiques ou neurofonctionnelles au niveau du groupe. Bien que ces techniques analytiques univariées aient contribué à des avancées significatives dans notre compréhension de la base neurobiologique des troubles psychiatriques et neurologiques, ces techniques traditionnelles présentent deux limites majeures [10]. Premièrement, les inférences statistiques sont tirées de multiples comparaisons indépendantes de différentes parties du cerveau, en partant du principe que ces différentes régions cérébrales locales agissent indépendamment

et que la connectivité fonctionnelle peut être ignorée. Cependant, de même qu'il a été dit précédemment que la meilleure façon de trouver des biomarqueurs pour les TSA est probablement d'analyser les changements de fonctionnalité du cerveau humain dans son ensemble plutôt que les altérations locales, de nombreuses études ont conclu que cette approche au niveau du réseau devrait également être adoptée pour plusieurs autres troubles psychiatriques et neurologiques [11]. Par ailleurs, les techniques statistiques traditionnelles de neuro-imagerie peuvent être utilisées pour mettre en évidence les différences entre les groupes, mais elles ne permettent pas de faire des inférences statistiques au niveau individuel. Or, dans la pratique quotidienne des cliniciens, les décisions de diagnostic et de traitement doivent être prises à ce niveau individuel [10].

- **III.3.2 Apprentissage automatique**

Pour tenter de surmonter les limites des méthodes traditionnelles, un intérêt croissant pour les MAA a été développé au sein de la communauté de neuro-imagerie. Les MAA sont multivariés et peuvent donc prendre en compte l'intercorrélation entre les différentes régions du cerveau, ce qui permet de surmonter la première limite posée par les techniques univariées traditionnelles [12]. En outre, les inférences statistiques au niveau des sujets Individuels sont possibles grâce aux méthodes d'apprentissage machines, ce qui permet de surmonter la deuxième limite [12]. En surmontant les deux principales limites des techniques traditionnelles, les applications de l'apprentissage automatique dans la recherche en neuro-imagerie ont permis d'améliorer considérablement la classification basée sur l'IRMf pour un diagnostic rapide et objectif des troubles mentaux, tels que l'autisme. Ces avancées ouvrent la voie à des approches plus personnalisées dans le traitement et la compréhension des maladies neurologiques, en permettant une identification précoce et précise des biomarqueurs associés à ces conditions [13].

- **III.3.3 Apprentissage profond**

Alors que les MAA comme les SVM restent une technique populaire pour classer les tâches à l'aide de données de neuro-imagerie, l'apprentissage profond a récemment suscité une attention considérable dans la communauté de la neuro-imagerie. Les méthodes d'apprentissage profond sont une sorte de méthodes d'apprentissage par représentation, ce qui signifie qu'elles peuvent apprendre automatiquement des caractéristiques pertinentes dans des ensembles de données sans avoir à les sélectionner [14].

De plus, comme les méthodes d'apprentissage profond impliquent des structures hiérarchiques avec différents niveaux de complexité, des niveaux croissants d'abstraction peuvent être atteints, ce qui permet d'extraire des caractéristiques de haut niveau des données qui sont moins affectées par le bruit des données d'entrée [14].

Cette capacité à gérer des données complexes et bruyantes rend les méthodes d'apprentissage profond

particulièrement adaptées pour analyser de grandes quantités d'informations issues de l'imagerie cérébrale, des tests génétiques et d'autres sources cliniques, Cette approche a conduit à des avancées significatives dans le diagnostic précoce de maladies, permettant aux chercheurs et cliniciens d'identifier des modèles qui pourraient autrement passer inaperçus, Ces progrès ouvrent la voie à des traitements personnalisés et ciblés, améliorant ainsi les résultats pour les patients tout en réduisant le temps nécessaire pour développer de nouvelles thérapies.

I.4 Réseaux neuronaux convolutifs

Les réseaux de neurones convolutifs (CNN) sont un type de réseau de neurones profonds dont l'architecture est vaguement basée sur la structure biologique du cortex visuel dans le cerveau humain, qui est la région du cerveau qui traite les informations visuelles, Ces réseaux sont particulièrement efficaces pour analyser des images et des données visuelles, ce qui les rend essentiels dans des domaines tels que l'imagerie médicale, où ils peuvent détecter des anomalies avec une précision remarquable [15]. Essentiellement, un CNN est un réseau neuronal artificiel composé d'une couche d'entrée, d'une ou de plusieurs couches cachées et d'une couche de sortie, toutes composées de nœuds ou de neurones qui sont connectés aux neurones des couches suivantes (voir figure 3.2) [15].

Les CNN relèvent de la branche de l'apprentissage automatique supervisé, ce qui signifie qu'un CNN est essentiellement un algorithme capable de généraliser des règles ou des modèles à partir d'un ensemble étiqueté de données d'entrée et d'utiliser ces connaissances pour faire des prédictions et des classifications sur des données inédites [16].

Pour fournir une compréhension essentielle de la fonctionnalité des CNN, sept concepts importants seront discutés : convolution, non-linéarité (ReLU), pooling, classification, optimisation, régularisation. Chacune de ces sept composantes est examinée dans les sous-sections ci-dessous, suivie d'un bref aperçu des résultats de la classification de l'autisme à la pointe de la technologie obtenus en utilisant une approche basée sur CNN.




Figure 3. 2 Architecture abstraite d'un réseau de neurones [16]




Figure 3. 1 Architecture générique des réseaux neuronaux convolutifs [15]

• III.4.1 Convolution

Le but principal des couches convolutionnelles dans un CNN est d'extraire les caractéristiques d'une image d'entrée. Les détails mathématiques de l'étape de convolution ne seront pas discutés ici, mais une compréhension intuitive du fonctionnement de la convolution sera présentée. La figure 3.1 donne un aperçu global de l'opération de convolution. Essentiellement, trois éléments sont impliqués dans l'opération de convolution : l'image d'entrée (ou les caractéristiques d'entrée dans les couches plus profondes), un filtre et une carte de caractéristiques et la sortie.

Premièrement, une image d'entrée peut être représentée par une matrice 2D, dans laquelle les valeurs des pixels sont représentées par des nombres. Deuxièmement, le filtre, souvent appelé aussi détecteur de caractéristiques ou noyau, est une matrice plus petite (par exemple une matrice 3x3) qui glisse sur l'image d'entrée. Cette plus petite

matrice, qui peut être considérée comme un petit patch ou une fenêtre, glisse constamment sur différentes positions de l'image d'entrée et, pour chaque position, calcule la multiplication matricielle par éléments entre le filtre et la partie de l'image d'entrée qui est actuellement "couverte" par le filtre. La sortie de ce calcul par position donne un seul nombre, qui forme ensuite un seul élément dans la matrice de sortie. Cette matrice de sortie est appelée carte de caractéristiques et est complétée lorsque le filtre a glissé sur l'ensemble de l'image d'entrée. La carte des caractéristiques, qui est une matrice 2D, est maintenant de plus petite dimension que l'image d'entrée, mais l'idée principale est que les filtres détectent des caractéristiques spécifiques dépendantes du filtre (par exemple, des lignes ou des courbes) dont la présence est représentée dans la carte des caractéristiques correspondante. En d'autres termes, un filtre spécifique apprend la présence d'une certaine caractéristique dans une image d'entrée, et représente ensuite cette présence dans une carte de caractéristiques résultante. Dans une couche convolutionnelle, plusieurs filtres sont normalement appliqués, qui développent une carte de caractéristiques une par une et empilent ces cartes de caractéristiques les unes par rapport aux autres. La sortie d'une couche convolutionnelle est donc une pile de cartes de caractéristiques

- **III.4.2 Non-linéarité (ReLU)**

ReLU signifie Rectified Linear Unit (Unité Linéaire Rectifiée) et est une fonction d'activation non-linéaire, qui est appliquée à chaque opération convolutive. Le but principal de ReLU est d'introduire la non-linéarité dans le CNN. ReLU est appliqué pour introduire cette non-linéarité, car toutes les opérations convolutionnelles sont des opérations linéaires (par exemple, les multiplications de matrice), et il est bénéfique pour les réseaux neuronaux de bien apprendre sur des données non linéaires aussi. La sortie de l'activation ReLU d'un nœud est donnée par l'équation suivante 3.1, ReLU remplace essentiellement toutes les valeurs négatives des pixels de la carte de données par zéro [17].

Ce qui signifie que certains neurones du CNN ne sont pas du tout activés dans la production de la sortie éventuelle parce que leur activation est fixée à zéro. Il s'agit souvent d'une propriété souhaitable des CNN, car ces neurones "morts" à l'intérieur des réseaux peuvent conduire à des modèles concis qui ont un meilleur pouvoir prédictif et moins de surajustement (Overfitting) [17]. De plus, il est plus probable que les neurones activés traitent des caractéristiques significatives de l'image d'entrée. En outre, les processus de calcul dans un réseau clairsemé sont également plus rapides que dans un réseau dense, car il y a moins de choses à calculer.

L'inconvénient de la rareté dans les réseaux, cependant, est que trop de neurones peuvent mourir, ce qui peut entraîner une détérioration des performances et une grande partie du réseau à être considérée comme inutile. La solution à ce problème pourrait être la mise en œuvre d'une fonction d'activation ReLU "fuyante", qui empêche les neurones de mourir. Outre l'avantage possible de la sparsité, ReLU présente également un avantage par rapport aux autres fonctions d'activation car elle a un faible coût de calcul, étant donné qu'il n'y a pas de mathématiques compliquées. Cela fait de ReLU la fonction d'activation la plus populaire et la plus utilisée actuellement dans les CNN [16-17].

$$R(x) = \max(0, x) \text{ (Activation ReLU)} \quad (3.1)$$

- **III.4.3 Mise en commun**

Après que les cartes de caractéristiques qui ont été formées dans la couche convolutionnelle ont été rectifiées par la fonction ReLU, un autre type de couche est généralement traversé dans le CNN : la couche de mise en commun. La fonction principale des couches de mise en commun dans les CNN est d'assurer la réduction de la dimensionnalité des cartes de caractéristiques tout en conservant les informations les plus importantes dans ces cartes de caractéristiques. Cette réduction de la dimensionnalité est utile, car elle rend les représentations d'entrée plus petites et donc plus faciles à gérer. De plus, le nombre de paramètres et de calculs est fortement réduit dans le réseau, ce qui permet de contrôler les besoins en calcul. Cela fait de l'opération de pooling une fonctionnalité nécessaire et importante dans l'architecture des CNNs [17].

Le regroupement ou le sous-échantillonnage spatial peut être de différents types (par exemple, regroupement max, moyen ou total), mais le processus sous-jacent est très similaire. Dans le processus de mise en commun maximale, comme pour les couches convolutives, un voisinage spatial local est défini de manière itérative par une approche de fenêtre glissante. Ce voisinage ou cette région spatiale est défini(e) par une petite fenêtre (par exemple, une région de 2x2) et, de manière itérative, pour chaque position que la fenêtre peut prendre, l'élément le plus grand apparaissant dans la région la plus basse de la carte de caractéristiques est pris et placé dans la matrice de sortie de la couche de mise en commun. La figure 3.3 donne un aperçu schématique de cette opération. Au lieu de prendre l'élément le plus grand, on peut aussi prendre la moyenne des éléments comme élément de sortie (pooling moyen), ou la somme de tous les éléments (pooling total), ou toute autre fonction qui calcule une valeur sur la région locale de la carte des caractéristiques [18]. Cependant, la mise en commun max s'est avérée nettement plus performante que les autres méthodes de sous-échantillonnage dans les tâches de traitement d'images et constitue donc probablement le meilleur choix de fonction de mise en commun dans la pratique.




Figure 3. 3 Opération Max Pool [15].

• III.4.4 Classification

Afin d'obtenir des prédictions de classe réelles en sortie d'un CNN, une ou plusieurs couches entièrement connectées sont traversées dans la partie finale du modèle. Ici, "entièrement connecté" implique que, contrairement aux couches convolutionnelles (où les filtres peuvent être considérés comme des nœuds), chaque neurone des couches entièrement connectées est connecté à chaque neurone de la couche suivante (voir figure 3.4). Alors que les couches convolutionnelles et de mise en commun servent à représenter les caractéristiques de haut niveau de l'image d'entrée, les couches entièrement connectées constituent généralement une méthode pratique d'apprentissage des combinaisons non linéaires de ces caractéristiques. Cette extraction de caractéristiques significatives d'une image d'entrée est utilisée pour la tâche de classification qui est effectuée dans la dernière couche entièrement connectée. L'activation de la fonction SoftMax dans la couche finale produit des probabilités de prédiction par classe dont la somme est égale à un. Ces probabilités de prédiction sont ensuite utilisées pour classer l'image d'entrée initiale dans l'une des classes cibles.

Lorsque des données d'imagerie sont traitées par un CNN, des images sont fournies en entrée du réseau et lorsque toutes les couches précédemment décrites du réseau ont été traversées, des scores de prédiction sont renvoyés pour ces images (la passe de feed-forward). Les réseaux CNN sont généralement constitués de plusieurs couches qui peuvent comprendre des centaines de nœuds, eux-mêmes connectés à des nœuds de couches adjacentes, ce qui donne des milliers ou des millions de connexions entre les nœuds d'un réseau.

Dans le cadre du processus de génération de prédictions de sortie à partir d'images d'entrée, chaque nœud d'une couche produit une sortie qui est ensuite transmise comme entrée pour le nœud connecté de la couche

suivante, de manière similaire à la transmission de signaux électriques par les neurones du cerveau humain. La sortie d'un nœud individuel est produite en multipliant la valeur d'entrée par une certaine valeur de poids initiale θ et, éventuellement, en ajoutant un terme de biais β is à ce résultat (voir l'équation 3.2). Par conséquent, vu d'un CNN dans son ensemble, la sortie est déterminée par les valeurs de poids individuelles de tous les nœuds dans le processus de feed-forward. Pour permettre à un réseau de faire des prédictions utiles, toutes ces valeurs de poids (les paramètres) sont ajustées dans un processus connu sous le nom de formation.

Dans le processus de formation d'un CNN, on utilise une méthode connue sous le nom de rétropropagation, qui est représentée schématiquement à la figure 3.4 [15]. Dans le processus d'apprentissage d'un CNN, les images de l'ensemble d'apprentissage sont transmises au réseau et, par la suite, la prédiction de sortie du réseau basée sur sa configuration actuelle des paramètres est comparée quantitativement à la véritable prédiction des images (par exemple, les étiquettes cibles des images). Cette comparaison s'effectue au moyen d'une fonction d'erreur, également appelée "fonction de perte". Dans le processus de rétropropagation, en partant de la couche de sortie et en se déplaçant vers les couches précédentes, les valeurs de poids de tous les nœuds du réseau sont légèrement ajustées dans une direction qui minimise la fonction de perte du réseau (le passage en arrière). Ce léger ajustement est déterminé en multipliant la dérivée de la fonction de perte (c'est-à-dire le gradient de la fonction de perte) par un taux d'apprentissage η choisi par l'utilisateur, qui détermine la taille des étapes d'apprentissage (voir l'équation 3.3). La technique de minimisation de la fonction de perte est connue sous le nom de descente de gradient, et est représentée schématiquement à la figure 3.5.

La mise à jour des valeurs de poids est effectuée de manière itérative, en traitant les images d'apprentissage sur plusieurs époques, une époque correspondant à un cycle complet de traitement de toutes les images de l'ensemble d'apprentissage. De plus, la mise à jour des valeurs de poids peut être effectuée après avoir calculé la fonction de perte pour un seul échantillon d'apprentissage (descente de gradient stochastique), un petit sous-ensemble de l'ensemble d'apprentissage (descente de gradient par mini-batch) ou l'ensemble de l'ensemble d'apprentissage (descente de gradient par batch). La mise à jour des valeurs en utilisant l'ensemble de l'apprentissage en tant que lot peut être coûteuse en termes de calcul et, par conséquent, la descente de gradient en mini-batch est le plus souvent utilisée dans le domaine de la recherche, ce qui permet une mise à jour plus douce des paramètres et une convergence plus stable [19]. Le processus d'optimisation est poursuivi jusqu'à la convergence de la fonction de perte, ce qui signifie que le réseau a atteint un état dans lequel la configuration des paramètres est optimale. Lorsque la mise à jour des valeurs de poids ne conduit plus à une diminution de la fonction de perte, le modèle a convergé et peut être considéré comme entraîné.

$$\text{Output}(x) = \theta x + \beta(\text{Nodeoutput}) \quad (3.2)$$

$$\theta_{\text{updated}} = \theta - \eta \cdot \frac{\delta}{\delta \theta} L(\theta) (\text{Weightupdate}) \quad (3.3)$$




Figure 3. 4 Représentation schématique du processus de rétropropagation [15].





Figure 3. 5 Méthode de descente du gradient pour minimiser la fonction de perte [19].

III.4.6 Surajustement et régulation


Comme expliqué dans la section précédente, un CNN apprend en ajustant un très grand nombre de paramètres de façon à minimiser la perte sur l'ensemble d'apprentissage. Après l'entraînement, la propriété souhaitable d'un CNN est qu'il peut également faire de bonnes prédictions sur des données non vues auparavant (c'est-à-dire un ensemble de données de test). Cette propriété de pouvoir prédictif élevé est également connue sous le nom de généralisabilité. Cependant, étant donné que la formation des CNN implique l'estimation d'un grand nombre de paramètres, il est possible que le modèle apprenne des fluctuations particulières dans les données de formation qui ne sont pas pertinentes pour la classification des données de test - un problème connu sous le nom de "suradaptation" [20]. Lorsqu'un CNN s'adapte trop bien, le modèle sera très performant sur l'ensemble d'apprentissage mais sera peu performant sur les données de test hors échantillon, manquant ainsi la caractéristique souhaitée de généralisation [21]. Le risque de surajustement est particulièrement élevé lorsque des méthodes d'apprentissage profond telles que les CNN sont appliquées à des données de neuro-imagerie, car la taille de l'échantillon des ensembles de données basés sur l'IRMf est généralement relativement petite, alors que la dimension des données est très élevée [20,21]. En d'autres termes, les ensembles de données de neuro-imagerie se composent généralement de peu d'échantillons, qui contiennent à leur tour beaucoup d'informations et de caractéristiques, ce qui augmente la probabilité d'un ajustement excessif aux données d'apprentissage.

Cependant, plusieurs stratégies ont été développées pour atténuer le risque de surajustement, connues collectivement sous le nom de "régularisation". En plus de la contribution à la régularisation de la fonction d'activation ReLU (en provoquant la sparsité du réseau), deux autres stratégies de régularisation populaires seront discutées ici. La première stratégie, connue sous le nom de dropout, est une technique peu coûteuse en termes de calcul qui sélectionne aléatoirement les neurones à ignorer pendant le processus de formation. Cela entraîne la sparsité du réseau d'une manière similaire à la sparsité causée par ReLU (voir la figure 3.6). L'abandon fait en sorte que les neurones soient aléatoirement "abandonnés", ce qui signifie que leur contribution à l'activation des neurones dans le passage vers l'avant est déplacée dans le temps et que les mises à jour de poids dans le processus de rétropropagation ne sont pas appliquées à ces neurones [22]. L'effet de l'abandon est que le réseau devient moins sensible aux poids spécifiques des neurones, ce qui donne un réseau qui peut atteindre des niveaux plus élevés de généralisation et qui est moins susceptible de s'adapter aux données d'apprentissage [21,22]. La deuxième stratégie de régularisation couramment utilisée est la normalisation par lot, une technique qui normalise la sortie d'une couche précédente en soustrayant la moyenne du lot et en

la divisant par l'écart type du lot. Ce faisant, chaque lot est prétraité pour obtenir une moyenne nulle et un écart type égal à un avant d'entrer dans la couche suivante [23]. La normalisation des lots s'est avérée améliorer à la fois la vitesse et la généralisation de la formation des réseaux neuronaux et est donc devenue un instrument populaire pour améliorer la performance et la stabilité des CNN [23].



(a) Réseau neuronal entièrement connecté



(b) Application de l'abandon avec $p \approx 0,5$

Figure 3. 6 Dropout appliqué aux couches entièrement connectées.

III.5.1.1 Résumés IRMF

Amplitude des fluctuations de basse fréquence (ALFF/fALFF)

L'ALFF mesure l'amplitude de la fluctuation à basse fréquence du signal IRMF. Comme les fluctuations de l'activité sont une caractéristique fondamentale de la connectivité fonctionnelle du cerveau au repos, et que l'ampleur relative de ces fluctuations peut varier entre les régions du cerveau et les sujets, l'ALFF peut servir de marqueur de dysfonctionnement cérébral [24]. En outre, l'ALFF fractionnel (fALFF) est directement dérivé de la mesure de l'ALFF. Dans les mesures fALFF, l'amplitude des fluctuations de basse fréquence est divisée par l'ensemble des fluctuations, ce qui permet de représenter la contribution relative de fluctuations spécifiques à l'ensemble de la gamme de fréquences [24]. Cette approche offre une meilleure compréhension des réseaux cérébraux en mettant en évidence les régions présentant des variations significatives dans leur activité, ce qui peut être particulièrement utile pour identifier des anomalies associées à diverses pathologies neurologiques.

Autocorrélation

L'autocorrélation mesure la dépendance statistique des valeurs des voxels sur une série temporelle. En mesurant la dépendance des valeurs des voxels entre des points de temps contigus, la corrélation entre les valeurs passées et les valeurs futures peut être mesurée et les états actuels est calculée.

De cette manière, l'autocorrélation peut servir de marqueur de la connectivité fonctionnelle de voxels ou de régions cérébrales distantes [25], Cette approche permet d'identifier les motifs d'activité cérébrale qui peuvent être associés à des fonctions cognitives spécifiques, offrant ainsi un aperçu précieux sur le fonctionnement du cerveau et ses réseaux interconnectés.

Centralité de degré (binarisé/pondéré)

Le degré de centralité est une mesure de la connectivité du réseau local qui représente le nombre de connexions directes qu'un nœud (voxel) a avec d'autres nœuds (voxels). Ainsi, une région du cerveau présentant un nombre élevé de connexions aura un degré de centralité élevé. Parmi les nombreux nœuds qui forment le réseau du cerveau entier, la centralité de degré indique lesquels de ces nœuds peuvent être considérés comme centraux dans le réseau. De plus, dans le calcul de la centralité de degré, la centralité de degré binarisée représente les forces de connexion entre les nœuds comme 0 ou 1 lors du calcul du nombre de connexions, tandis que la centralité de degré pondérée utilise la force de connexion comme une valeur de relation continue [26], Ces différentes approches permettent d'analyser plus finement la structure et le fonctionnement des réseaux cérébraux, offrant ainsi une meilleure compréhension des mécanismes sous-jacents aux processus cognitifs et comportementaux.

Densité de connectivité fonctionnelle locale (LFCD) (binarisée/pondérée)

Le LFCD est une autre mesure de la connectivité des réseaux locaux. Cette technique peut être appliquée aux données d'IRMf pour détecter les nœuds (régions) du cerveau humain dont le nombre de connexions dépasse largement la moyenne. Essentiellement, le LFCD calcule la connectivité du réseau local en explorant les voisins d'un nœud et les voisins de ses voisins jusqu'à ce que les connexions deviennent plus faibles qu'une valeur seuil donnée par l'utilisateur [27].

Par la suite, si un nœud a un nombre élevé de nœuds voisins qui ont été explorés, une valeur LFCD élevée lui sera attribuée, ce qui indique une connectivité fonctionnelle élevée. Comme pour la centralité de degré, la valeur binarisée de la LFCD utilise la force de connexion représentée par 0 ou 1 dans le calcul, tandis que la

LFCD pondérée utilise les forces de connexion comme des valeurs continues [26].

En identifiant ces nœuds clés, les chercheurs peuvent mieux comprendre comment certaines régions du cerveau interagissent et contribuent à des fonctions cognitives spécifiques, ouvrant la voie à de nouvelles recherches sur les troubles neurologiques et psychiatriques.

Centralité du vecteur propre (binarisé/pondéré)

Alors que la centralité des degrés est une mesure de la connectivité locale du réseau, la centralité des vecteurs propres est une mesure de la connectivité globale du réseau. La centralité du vecteur propre d'un nœud donné dans un réseau est mesurée par le nombre de connexions directes qu'il a avec d'autres nœuds qui ont une centralité élevée. Par conséquent, la centralité du vecteur propre d'un nœud donné ne dépend pas seulement de sa propre centralité, mais aussi de la centralité des nœuds auxquels il est connecté [25]. Ainsi, une région du cerveau (voxel) présentant une centralité de vecteur propre élevée est connectée à de nombreuses autres régions qui sont elles-mêmes hautement connectées et centrales dans le réseau. Là encore, la centralité des vecteurs propres binarisés utilise des valeurs discrètes pour les forces de connexion dans le calcul, tandis que la centralité des vecteurs propres pondérés utilise des valeurs continues [26].

Entropie

L'entropie est un concept qui mesure la complexité d'un système. Une complexité accrue signifie une entropie plus élevée, tandis qu'une complexité réduite signifie une entropie plus faible. En outre, l'entropie du cerveau a été définie comme le nombre d'états neuronaux auxquels un cerveau peut accéder [28]. On sait que des régions du cerveau humain s'organisent de manière transitoire en réseaux fonctionnellement connectés pendant de brèves périodes, pour se réorganiser quelques instants plus tard en éléments d'un réseau dont la structure et la fonctionnalité sont différentes [29]. Ainsi, l'entropie d'un voxel peut être calculée à partir d'une série temporelle d'IRMf en déterminant le nombre d'états cérébraux (approximativement) stables auxquels un réseau a accédé pendant une brève période de temps.

Homogénéité régionale (ReHo)

ReHo fournit des informations sur l'activité locale des régions du cerveau en évaluant la similarité ou la synchronisation entre les séries temporelles d'un voxel donné et de ses voxels voisins [30]. Cette mesure de l'activité cérébrale basée sur les voxels repose sur l'hypothèse que l'activité cérébrale se manifeste par le regroupement de groupes de voxels, plutôt que de voxels individuels [26].

Connectivité homotopique à miroir de voxel (VMHC)

Le VMHC est une mesure de l'homotopie fonctionnelle, c'est-à-dire de la synchronisation des schémas d'activité entre des régions homotopiques (géométriquement correspondantes) dans chaque hémisphère du cerveau [31].

En outre, le VMHC mesure la connectivité par voxel entre les deux hémisphères du cerveau, en calculant la connectivité de tous les voxels d'un hémisphère et de leur équivalent dans l'autre hémisphère. Comme la variation de l'homotopie fonctionnelle peut varier entre les régions et les sujets, le VMHC peut servir de marqueur pour les troubles cérébraux [31].

III.5.1.1 Données prétraitées : vue d'ensemble

Après le prétraitement des IRM structurales et fonctionnelles, les données d'entrée brutes ont été divisées en 13 ensembles de données distincts : 1 résultant des données d'IRM structurales pondérées en T1, et 12 résultants de la synthèse des données d'IRMf à l'aide de différentes techniques. Tous ces ensembles de données distincts, que nous appellerons résumés, comprenaient 2122 sujets, chaque échantillon étant représenté par une image tridimensionnelle de dimension 45x54x45. Le tableau 3.1 donne un aperçu de tous les résumés avec leur abréviation respective et une brève description.

Abréviation	Fonction	Mesure
T1w	IRM structurelle	Informations sur l'IRM structurelle
ALFF	Fluctuations de fonction (activité)	Amplitude des fluctuations de basse fréquence
fALFF	Activité fonctionnelle	Amplitude fractionnée des fluctuations de basse fréquence
Autocorr	Corrélation cérébrale	Corrélation globale intra-cerveau
IFCD ^b	Connectivité locale (binarisée)	Densité de connectivité fonctionnelle locale
IFCD ^w	Connectivité locale (pondérée)	Densité de connectivité fonctionnelle locale
DC ^b	Connectivité du réseau local	Centralité de degré (binarisé)
DC ^w	Connectivité du réseau local	Centralité de degré (pondérée)
EC ^b	Connectivité du réseau mondial	Centralité des vecteurs propres (binarisé)
EC ^w	Connectivité du réseau mondial	Centralité des vecteurs propres (pondérée)
Entropie	Complexité du réseau	Entropie
ReHo	Activité du réseau régional	Homogénéité régionale
VMHC	Homotopie fonctionnelle	Connectivité homotopique en miroir de voxel
Acc. moyen	—	—

Table 10 Vue d'ensemble de tous les ensembles de données de synthèse

III.5.2 Mise en œuvre du réseau

Dans cette section, les détails de l'implémentation du CNN 3D standard seront fournis. Pour ce faire, nous présenterons la conception architecturale du réseau et du choix de la fonction de perte, de l'optimiseur et des techniques de régularisation.

III.5.2.1 Fonction de perte

L'optimisation dans un CNN est réalisée en minimisant la fonction de perte, qui représente l'erreur de classification. Différentes fonctions de perte peuvent être utilisées dans les tâches de classification d'images, mais dans cette thèse, la fonction de perte d'entropie croisée a été implémentée pour les deux modèles CNN. L'entropie croisée, également appelée perte logarithmique, est une fonction de perte populaire pour les tâches de classification binaire [32], et est mathématiquement définie comme suit :

$$\mathcal{L} = \frac{1}{N} \sum_{i=1}^N - \left(y_i \cdot \log(P(y_i)) + (1 - y_i) \cdot \log(1 - P(y_i)) \right) \quad (\text{cross-entropy loss}) \quad (3.4)$$

Où y_i indique l'étiquette réelle d'un échantillon i (0 ou 1) et $P(y_i)$ indique le score de probabilité prédit de cet échantillon appartenant à la classe 1. En suivant cette équation, et le fait que y peut être soit 0 soit 1, on peut distinguer deux cas différents :

Cas 1 : L'étiquette vraie d'un échantillon est 1 ($y^{\text{vrai}} = 1$), ce qui donne la fonction de perte :

$$L(y^{\text{vrai}} = 1) = -\log P(y = 1)$$

Cas 2 : L'étiquette vraie d'un échantillon est 0 ($y^{\text{vrai}} = 0$), ce qui donne la fonction de perte :

$$L(y^{\text{vrai}} = 0) = -\log 1 - P(y = 1)$$

En substituant $1 - P(y = 1)$ par $P(y = 0)$ ¹ on obtient :

$$L(y^{\text{vrai}} = 0) = -\log P(y = 0)$$

Donc, ce que la fonction de perte d'entropie croisée fait essentiellement, c'est que pour chaque échantillon avec la vraie classe 1, elle ajoute la probabilité logarithmique négative de prédiction de son appartenance à la classe 1, et pour chaque échantillon avec la vraie classe 0, elle ajoute la probabilité logarithmique négative de prédiction de son appartenance à la classe 0.

¹Ceci découle de la propriété de la fonction SoftMax pour la classification binaire, où $P(y = 0) + P(y = 1) = 1$

Dans la dernière étape de la fonction de perte d'entropie croisée, la perte totale est divisée par le nombre d'échantillons classés, et la valeur moyenne restante de la perte d'entropie croisée est retournée. En prenant le log négatif sur les probabilités de prédiction, l'entropie croisée renvoie des valeurs élevées pour les classifications erronées avec une confiance élevée, tout en renvoyant des valeurs faibles pour les classifications correctes avec une confiance élevée. la figure suivante illustre ce phénomène : à mesure que la probabilité prédite de la classe réelle se rapproche de zéro, la perte augmente de manière exponentielle. Il s'agit d'une caractéristique souhaitable des fonctions de perte dans les tâches de classification, car elle garantit la punition des mauvaises prédictions. Pour cette raison, l'entropie croisée a été choisie comme fonction de perte dans cette thèse.




Figure 3. 7 Fonction de perte d'entropie croisée.

III.5.2.2 Optimiseur

La fonction de perte est minimisée en utilisant des méthodes de descente de gradient. Dans cette thèse, l'optimiseur Adam a été utilisé pour minimiser la perte d'entropie croisée, qui est un algorithme qui peut remplacer les méthodes traditionnelles de descente de gradient stochastique [33]. Adam est une méthode de taux d'apprentissage adaptatif, ce qui signifie qu'il calcule des taux d'apprentissage individuels pour différents paramètres. De plus, il a été démontré que Adam améliore les performances sur les problèmes d'optimisation non convexes [34]. Les problèmes d'optimisation non convexes sont des problèmes qui peuvent avoir plusieurs solutions localement optimales, ce qui rend difficile d'identifier si le problème a une solution optimale globale [35]. L'utilisation d'Adam pour les problèmes d'optimisation non Convexes présente plusieurs autres avantages : la méthode est simple à mettre en œuvre, efficace en termes de calcul, peu exigeante en mémoire et bien adaptée aux problèmes de grande taille en termes de données ou de paramètres [33]. Ces avantages attrayants et le fait que de nombreux résultats empiriques ont démontré que

l'algorithme Adam se compare favorablement à d'autres méthodes d'optimisation stochastique [33], ont conduit au choix d'utiliser l'algorithme Adam comme optimiseur dans le processus de formation des CNN.

III.5.1 Approche

Cette section détaillera l'approche générale qui a été adoptée dans cette recherche, qui a finalement servi à la classification de l'autisme par le réseau 3D CNN standard. On peut distinguer quatre étapes dans l'approche globale, qui seront couvertes dans les sous-sections ci-dessous.

III.5.1.1 Division des données

La première étape a consisté à diviser les 13 ensembles de données récapitulatives en ensembles distincts de formation, de validation et de test. La répartition des 2122 échantillons dans ces trois sous-ensembles a été effectuée selon les proportions suivantes : 20% des données ont formé l'ensemble de test, et 80% de tous les échantillons ont constitué la base de l'ensemble d'entraînement et de validation, où le rapport d'entraînement/validation dans ces 80% de tous les échantillons était également 80/20, respectivement. Le tableau 3.2 donne un aperçu de la taille des sous-ensembles d'entraînement, de validation et de test obtenus. Ainsi, après division, chaque ensemble de données récapitulatif est divisé en trois sous-ensembles, créant ainsi 13 ensembles distincts de formation, de validation et de test.

Sous-ensemble	Nombre d'échantillons
Train	1538
Validation	340
Test	424

Table 11 Nombre d'échantillons dans les sous-ensembles après la division de l'ensemble de données

III.5.1.2 Sélection des hyperparamètres

Les hyperparamètres sont utilisés dans le processus d'apprentissage des CNN. Qui représentent le choix de la taille du lot et du taux d'apprentissage. Les hyperparamètres ont été déterminés en entraînant les deux réseaux sur l'ensemble d'entraînement du résumé VMHC avec différentes tailles de lots et différents taux d'apprentissage². Par la suite, il a été déterminé empiriquement quelle combinaison de taille de lot et de taux d'apprentissage donnait la plus grande précision de validation par modèle et serait donc utilisée dans le reste des expériences.

III.5.1.1 Résumé des performances

Après avoir sélectionné empiriquement les valeurs optimales pour la taille du lot et le taux d'apprentissage, l'étape suivante a consisté à évaluer les performances des deux modèles sur les 13 ensembles de données sommaires. Pour ce faire, les deux réseaux ont été entraînés un par un sur les 13 ensembles d'entraînement résumés et testés sur l'ensemble de test correspondant. Dans la phase de formation, outre le suivi des performances du modèle sur les données de formation, les performances sur l'ensemble de validation ont également été suivies tout au long du processus de formation. Alors que la perte d'apprentissage peut continuer à diminuer pendant la formation, une augmentation de la perte de validation indique généralement le début d'un surajustement. Par conséquent, en suivant la perte de validation au cours du processus de formation, une méthode connue sous le nom d'arrêt précoce basé sur la validation peut être mise en œuvre, ce qui signifie que le processus de formation est arrêté lorsque la perte de validation ne diminue plus. L'idée est que cet arrêt précoce basé sur la validation conduit à un niveau plus élevé de généralisation, et donc à une meilleure performance sur des données non vues. Cependant, l'erreur de validation peut fluctuer pendant la formation en raison de minima locaux, et donc l'arrêt précoce basé sur la validation pourrait aboutir à des solutions sous-optimales. Pour éviter que cela ne se produise, les deux CNN ont été formés pendant un nombre fixe d'époques tout en gardant une trace de la perte de validation tout au long du processus de formation, et un point de contrôle du modèle a été créé si la perte de validation du modèle était inférieure à la perte de validation la plus faible précédemment. Après l'entraînement, la configuration des paramètres correspondant au point auquel la perte de validation était la plus faible était utilisée pour l'évaluation sur l'ensemble de test. Ainsi, au lieu de mettre en œuvre un arrêt précoce basé sur la validation, une sorte de technique d'extraction de modèle basée sur la validation a été mise en œuvre, ce qui garantit que le modèle utilisé pour le test a atteint la perte de validation la plus faible pendant le processus de formation.

² Le VMHC a été choisi comme résumé sur lequel s'entraîner pour déterminer les valeurs des hyperparamètres, parce que, aux premiers stades de la recherche, l'entraînement sur ce résumé a donné des résultats prometteurs à l'époque, sans trop d'ajustement. Comme il faudrait beaucoup plus de temps pour tester de manière approfondie la performance de validation de toutes les valeurs d'hyperparamètres sur tous les résumés, on a choisi de sélectionner les valeurs d'hyperparamètres en se basant uniquement sur la performance du résumé VMHC.

III.5.1.2 Validation croisée à 5 reprises

Les performances des résumés, comme expliqué dans la section précédente, n'ont été testées qu'une seule fois (en utilisant la division initiale des données), car il aurait fallu beaucoup de temps pour évaluer les performances des 13 résumés en utilisant plusieurs divisions des données en sous-ensembles. Cependant, les résultats d'un test unique peuvent être raisonnablement biaisés et trompeurs, et donc une analyse un peu plus approfondie des performances des deux CNN était l'étape suivante de la comparaison des performances. Pour ce faire, les deux résumés les plus performants ont d'abord été sélectionnés empiriquement à partir des résultats des tests ponctuels. Ensuite, un schéma de validation croisée 5 fois a été mis en œuvre pour générer des résultats de test plus nuancés. Cela signifie que les deux ensembles de données de résumé ont été divisés en cinq plis de taille égale et que, pendant cinq itérations de test, l'un de ces plis a servi d'ensemble de test d'attente, tandis que les autres plis combinés formaient l'ensemble d'entraînement. De plus, au cours de ces cinq itérations, la même technique d'extraction de modèle basée sur la validation que celle expliquée précédemment a été appliquée en divisant les quatre plis non testés en un ensemble d'apprentissage et un ensemble de validation avec un rapport 80/20, respectivement. Dans l'approche de validation croisée adoptée, plusieurs métriques d'évaluation ont été mises en œuvre pour mesurer les performances, qui seront discutées en détail dans la section suivante.

III.5.1 Mesures d'évaluation

Comme indiqué dans l'introduction, l'objectif principal de cette thèse est de quantifier les anomalies des TSA par IRM et apprentissage profond, en examinant trois aspects différents : (1) la performance générale de classification basée sur l'ensemble du jeu de données, (2) l'impact de la taille de l'échantillon sur la performance de classification, et (3) le taux de convergence de l'apprentissage. La première sous-section ci-dessous aborde les métriques qui ont été utilisées pour déterminer la performance de classification générale, en clarifiant les termes suivants l'exactitude, la sensibilité et la spécificité. La deuxième sous-section présente le concept de l'analyse ROC-AUC, qui est une méthode qui a également été utilisée pour mesurer la performance de la classification générale. La troisième sous-section présente le concept de courbes d'apprentissage, qui a été la métrique d'évaluation pour analyser l'impact de la taille de l'échantillon sur la performance. Enfin, la dernière sous-section traite de la façon dont le taux de convergence a été mesuré et comparé.

autres plis combinés formaient l'ensemble d'entraînement. De plus, au cours de ces cinq itérations, la même technique d'extraction de modèle basée sur la validation que celle expliquée précédemment a été appliquée en divisant les quatre plis non testés en un ensemble d'apprentissage et un ensemble de validation avec un rapport 80/20, respectivement. Dans l'approche de validation croisée adoptée, plusieurs métriques d'évaluation ont été mises en œuvre pour mesurer les performances, qui seront discutées en détail dans la section suivante.

III.5.2 Mesures d'évaluation

Comme indiqué dans l'introduction, l'objectif principal de cette thèse est de quantifier les anomalies des TSA par IRM et apprentissage profond, en examinant trois aspects différents : (1) la performance générale de classification basée sur l'ensemble du jeu de données, (2) l'impact de la taille de l'échantillon sur la performance de classification, et (3) le taux de convergence de l'apprentissage. La première sous-section ci-dessous aborde les métriques qui ont été utilisées pour déterminer la performance de classification générale, en clarifiant les termes suivants l'exactitude, la sensibilité et la spécificité. La deuxième sous-section présente le concept de l'analyse ROC-AUC, qui est une méthode qui a également été utilisée pour mesurer la performance de la classification générale. La troisième sous-section présente le concept de courbes d'apprentissage, qui a été la métrique d'évaluation pour analyser l'impact de la taille de l'échantillon sur la performance. Enfin, la dernière sous-section traite de la façon dont le taux de convergence a été mesuré et comparé.

III.5.2.1 Précision, sensibilité et spécificité

Pour comprendre les concepts d'exactitude, de sensibilité et de spécificité, il est d'abord nécessaire d'expliquer la signification des termes vrai positif, faux positif, vrai négatif et faux négatif. En général, positif signifie qu'un sujet est identifié comme patient, tandis que négatif signifie qu'un sujet est identifié comme sain. Par conséquent, les définitions suivantes s'appliquent :

- Vrai positif (TP) = correctement identifié comme patient
- Faux positif (FP) = identifié à tort comme patient
- Vrai négatif (TN) = correctement rejeté comme sain
- Faux négatif (FN) = rejeté à tort comme sain

La précision est calculée en divisant le nombre d'échantillons correctement classés par le nombre total d'échantillons dans l'ensemble d'évaluation, comme le montre l'équation 3.5. La sensibilité, également appelée taux de vrais positifs (TPR) ou rappel, mesure la proportion de vrais positifs qui sont correctement identifiés comme tels, comme le montre l'équation 3.6 [36,37]. Dans le contexte de la classification des TSA, la sensibilité indique le pourcentage de patients atteints de TSA qui sont correctement identifiés comme étant autistes. La spécificité, également appelée taux de vrais négatifs (TNR), mesure la proportion de vrais négatifs qui sont

correctement identifiés comme tels, et est représentée par l'équation 3.7. Dans le contexte de la classification des TSA, la spécificité indique le pourcentage de personnes en bonne santé qui sont correctement identifiées comme telles [38]. La sensibilité et la spécificité sont des mesures statistiques largement utilisées en médecine, où une sensibilité élevée indique un test médical qui néglige rarement les vrais positifs (assurant ainsi le diagnostic si un sujet est atteint d'une maladie), et une spécificité élevée indique un test médical qui diagnostique rarement un sujet sain comme patient (assurant ainsi le rejet si un sujet n'est pas atteint d'une maladie). Bien que le classificateur médical optimal ait une sensibilité et une spécificité élevées, dans la pratique, il existe généralement une sorte de compromis entre ces deux valeurs [38].

$$\text{Précision} = \frac{TP+TN}{TP+FP+TN+FN} \quad (3.5)$$

$$\text{Sensibilité} = \text{TPR} = \frac{TP}{TP+FN} \quad (3.6)$$

$$\text{Spécificité} = \text{TNR} = \frac{TN}{TN+FP} \quad (3.7)$$

III.5.2.2 ROC-AUC

Comme le pouvoir diagnostique de tout test médical est déterminé à la fois par sa sensibilité et sa spécificité [38], il est utile d'explorer le compromis entre ces deux valeurs dans l'analyse des performances d'un classificateur. L'analyse de la caractéristique d'exploitation du récepteur (ROC) est une méthode permettant d'examiner le compromis entre la spécificité et la sensibilité [39]. Une courbe ROC est un tracé graphique qui illustre la capacité de diagnostic d'un classificateur binaire. La courbe ROC est créée en traçant le taux de vrais positifs (TPR), par rapport au taux de faux positifs (FPR) à différents seuils (la valeur de discrimination de classe). Le taux de vrais positifs est équivalent à la sensibilité (voir l'équation 3.6), tandis que le taux de faux positifs est également connu sous le nom de retombée ou probabilité de fausse alarme [39]. En outre, le taux de faux positifs peut être calculé par : $\text{FPR} = (1 - \text{Spécificité})$ (3.8)

En faisant varier la valeur du seuil, qui est le score de probabilité qui doit être dépassé pour classer un sujet comme étant un patient (avec une valeur par défaut de 0,5 dans les tâches de classification binaire), différentes valeurs de TPR et de FPR sont calculées et tracées pour former une courbe. Comme le TPR est équivalent à la sensibilité et que le FPR est directement dérivé de la spécificité (voir l'équation 3.7), chaque point d'une courbe ROC représente une paire de sensibilité et de spécificité correspondant à un seuil de décision particulier. En général, l'aire sous une courbe ROC indique la capacité d'un modèle à faire la distinction entre deux classes [40]. Les courbes ROC avec un score AUC (aire sous la courbe) élevé sont plus efficaces pour faire des prédictions que les courbes ROC avec des scores AUC faibles. De plus, la diagonale d'une courbe ROC représente une classification aléatoire, avec un score AUC correspondant de 0,5. Les classificateurs dont le score

AUC est supérieur à 0,5 sont donc plus performants que les classificateurs aléatoires, tandis que les classificateurs dont le score AUC est inférieur à 0,5 sont moins performants. Étant donné que l'analyse ROC-AUC offre des indications utiles sur la capacité de diagnostic des modèles, les scores AUC ont également été utilisés pour évaluer la performance de la classification dans le schéma de validation croisée 5-fois, en plus des mesures de précision, de sensibilité et de spécificité décrites précédemment.

III.5.2.3 Courbes d'apprentissage

Une courbe d'apprentissage mesure l'impact du nombre d'échantillons d'entraînement sur la performance d'un modèle prédictif et est construite en traçant le nombre d'échantillons d'entraînement utilisés par rapport à une certaine mesure d'évaluation (par exemple, le score de précision) qui est effectuée sur un ensemble de test constant [41]. Deux courbes d'apprentissage différentes ont été construites pour comparer les performances des deux modèles CNN en fonction de la taille des échantillons. La première courbe d'apprentissage trace les scores de précision des tests en fonction du nombre d'échantillons d'entraînement utilisés, tandis que la deuxième courbe d'apprentissage trace les scores AUC en fonction du nombre d'échantillons utilisés. Dans ces graphiques, les scores de précision et d'AUC ont été calculés en augmentant chaque fois de 5% le ratio de la partie utilisée de l'ensemble d'entraînement, en commençant par 5% de l'ensemble d'entraînement utilisé et en terminant par l'ensemble de l'ensemble d'entraînement utilisé. Normalement, une courbe d'apprentissage croissante indique la capacité d'un modèle à obtenir des informations supplémentaires utiles lorsqu'il est entraîné sur davantage de données [41]. Dans cette thèse, cependant, l'utilisation des courbes d'apprentissage ne sert pas nécessairement à montrer l'amélioration des performances d'un modèle sur un plus grand nombre de données, mais plutôt à démontrer la qualité des performances d'un modèle lorsqu'il est entraîné sur moins de données.

III.5.2.4 Taux de convergence

Dans le processus de formation d'un CNN, l'optimiseur minimise la fonction de perte jusqu'à ce que la convergence se produise et que l'overfitting commence à se produire, ce qui signifie que la perte de validation ne diminue plus. Un graph a été construit qui illustre la perte de validation en fonction du nombre d'époques passées dans le processus de formation.

III.6 Résultats

Ce chapitre fournit tous les résultats des expériences qui ont été menées pour la classification de l'autisme par CNN. Un aperçu du code de ces expériences se trouve dans **l'annexe Partie C**.

III.6.1 Sélection des hyperparamètres

Les scores de précision de validation du modèle CNN utilisent différentes combinaisons d'hyperparamètres, le modèle a été entraîné pendant 50 époques, et la précision de validation a été calculée toutes les 5 époques. Une fois les 50 époques d'entraînement terminées, le score de validation le plus élevé a été soustrait et ensuite utilisé comme valeur d'entrée. Comme on peut le déduire, le CNN standard a obtenu une précision de validation (69,1 %) avec un taux d'apprentissage de 0,001 et une taille de lot de 64.

III.6.2 Résumé des performances

Le tableau 3.3 présente les résultats des tests uniques du modèle pour tous les résumés. Dans ce cas, le modèle a été entraîné sur les 13 ensembles d'entraînement de résumés pendant 50 époques, tout en utilisant l'ensemble de validation correspondant pour déterminer la configuration des valeurs de poids à utiliser pour l'évaluation sur l'ensemble de test d'attente. D'après le tableau 3.3, le modèle CNN n'a pas obtenu un score de précision élevé lorsqu'il a été entraîné sur le résumé de l'IRM structurelle T1w et le résumé de l'entropie, alors que les meilleures performances du CNN (69,1 % d'acc.) a été obtenue en utilisant les résumés ReHo et VMHC comme jeux de données, respectivement. Par conséquent, ces résumés ont été utilisés dans le processus de validation croisée pour générer des résultats de performance un peu plus nuancés et étendus.

Abréviation	Fonction	Mesure	3D CNN
T1w	IRM structurelle	Informations sur l'IRM structurelle	0.623
ALFF	Fluctuations de fonction (activité)	Amplitude des fluctuations de basse fréquence	0.657
fALFF	Activité fonctionnelle	Amplitude fractionnée des fluctuations de basse fréquence	0.650
Autocorr	Corrélation cérébrale	Corrélation globale intra-cerveau	0.657
IFCD ^b	Connectivité locale (binarisée)	Densité de connectivité fonctionnelle locale	0.635
IFCD ^w	Connectivité locale (pondérée)	Densité de connectivité fonctionnelle locale	0.627
DC ^b	Connectivité du réseau local	Centralité de degré (binarisé)	0.653
DC ^w	Connectivité du réseau local	Centralité de degré (pondérée)	0.657
EC ^b	Connectivité du réseau mondial	Centralité des vecteurs propres (binarisé)	0.653
EC ^w	Connectivité du réseau mondial	Centralité des vecteurs propres (pondérée)	0.657
Entropie	Complexité du réseau	Entropie	0.618
ReHo	Activité du réseau régional	Homogénéité régionale	0.691
VMHC	Homotopie fonctionnelle	Connectivité homotopique en miroir de voxel	0.681
Acc. moyen	—	—	0.651

Table 12 scores de précision du test unique pour l'entraînement du CNN sur tous les résumés.

III.6.3 Complexité de l'échantillon

La courbe d'apprentissage du modèle CNN évaluant l'effet de la taille de l'échantillon sur la précision, on peut conclure que la performance du modèle augmente lorsque la taille de l'ensemble d'entraînement devient plus grande comme illustré sur la figure 3.8. En effet, les performances du CNN semblent être bonnes lorsque l'ensemble d'apprentissage est à 60%.

Cependant, une augmentation des données d'entraînement au-delà de ce seuil peut continuer à améliorer la précision, mais il est également crucial de surveiller les signes de surapprentissage qui peuvent se produire si le modèle devient trop complexe par rapport à la quantité de données disponibles [42].

Il est donc essentiel d'optimiser l'architecture du modèle et d'appliquer des techniques de régularisation pour maintenir un équilibre entre la performance et la généralisation.

Val_accuracy

Val_accuracy/train
tag: Val_accuracy/train




Figure 3. 8 Courbes d'apprentissage CNN sur le résumé ReHo.

III.6.4 Convergence des pertes

La figure 3.9 montre la perte de validation du modèle en fonction du nombre d'époques passées à former le CNN sur le résumé ReHo. Le graph permet de conclure que le CNN semble converger vers une solution stable, indiquant que le modèle a atteint un niveau optimal de performance sans surajustement significatif aux données d'entraînement.




Figure 3. 9 Perte de validation pendant la formation ReHo.

III.7 Conclusion

L'objectif principal de ce chapitre était de classifier les TSA par le modèle CNN entraîné sur l'ensemble de données ABIDE.

Les résultats des expériences menées dans ce chapitre ont démontré le potentiel que les CNN peuvent offrir des bons résultats dans le domaine de la neuro-imagerie, en démontrant une meilleure performance globale de classification, une complexité d'échantillon réduite et un taux de convergence plus élevé que les autres modèles de l'apprentissage profond, les résultats de cette thèse sont tout de même encourageants, et ils dévoilent que des perspectives excitantes peuvent se présenter pour une implémentation plus poussée des CNNs dans le contexte de la neuro-imagerie.

Ces avancées ouvrent la voie à de nouvelles recherches qui pourraient explorer des architectures encore plus sophistiquées et adaptées, permettant ainsi d'améliorer davantage l'analyse des données neuro-imagées.

Ces recherches pourraient également inclure l'intégration de techniques d'apprentissage par transfert, qui ont le potentiel d'optimiser les performances des CNN en exploitant des modèles pré-entraînés sur des ensembles de données similaires [42], Cela pourrait également conduire à des collaborations interdisciplinaires, réunissant des experts en neurosciences, en informatique et en ingénierie pour développer des solutions innovantes qui transforment notre compréhension du fonctionnement cérébral.

III.8 Références

- [1] E. W. Pang et al., “Abnormal Brain Dynamics Underlie Speech Production in Children with Autism Spectrum Disorder,” 2016. doi: 10.1002/AUR.1526.
- [2] E. Conti et al., “Autism Spectrum Disorder and Childhood Apraxia of Speech: Early Language-Related Hallmarks across Structural MRI Study,” 2020. doi: 10.3390/JPM10040275.
- [3] K. Ziman, A. C. Heusser, P. C. Fitzpatrick, C. E. Field, and J. R. Manning, “Is automatic speech-to-text transcription ready for use in psychological experiments?,” 2018. doi: 10.3758/S13428-018-1037-4.
- [4] R. Ma, Y. Wang, Y. Wei, and Y.-C. Pan, “Meta-data Study in Autism Spectrum Disorder Classification Based on Structural MRI,” arXiv.org, Jun. 2022, doi: 10.48550/arXiv.2206.05052.
- [5] M. Wiklund and M. Laakso, “Comparison of Disfluent and Ungrammatical Speech of Preadolescents with and without ASD,” *Journal of Autism and Developmental Disorders*, Oct. 2020, doi: 10.1007/S10803-020-04747-2.
- [6] W. Guthrie, L. Swineford, C. Nottke, and A. M. Wetherby, “Early diagnosis of autism spectrum disorder: stability and change in clinical diagnosis and symptom presentation,” *Journal of Child Psychology and Psychiatry*, May 2013, doi: 10.1111/JCPP.12008.
- [7] J. Brisson, K. Martel, J. Serres, S. Sirois, and J.-L. Adrien, “Acoustic analysis of oral productions of infants later diagnosed with autism and their mother,” *Tradition*, May 2014, doi: 10.1002/IMHJ.21442.
- [8] Y.-H. Nah, R. L. Young, N. Brewer, and G. Berlinger, “Autism detection in early childhood (ADEC): reliability and validity data for a Level 2 screening tool for autistic disorder,” *Psychological Assessment*, Feb. 2014, doi: 10.1037/A0034472.
- [9] T. M. Evans et al., “Brain Structural Integrity and Intrinsic Functional Connectivity Forecast 6 Year Longitudinal Growth in Children’s Numerical Abilities,” *The Journal of Neuroscience*, Aug. 2015, doi: 10.1523/JNEUROSCI.0216-15.2015.
- [10] A. Todeva-Radneva, R. Paunova, S. Kandilarova, and D. Stoyanov, “The Value of Neuroimaging Techniques in the Translation and Transdiagnostic Validation of Psychiatric Diagnoses - Selective Review,” *Current Topics in Medicinal Chemistry*, Jan. 2020, doi: 10.2174/1568026620666200131095328.
- [11] P. Kassraian-Fard, C. Matthis, J. H. Balsters, M. H. Maathuis, and N. Wenderoth, “Promises, pitfalls, and basic guidelines for applying machine learning classifiers to psychiatric imaging data, with autism as an example,” *Frontiers in psychiatry*, vol. 7, p. 177, 2016.
- [12] C. G. Habeck, “Basics of multivariate analysis in neuroimaging data,” *Journal of Visualized Experiments*, Jul. 2010, doi: 10.3791/1988.
- [13] M. Shahnawaz and C. Soto, “Identification of biomarkers for diagnosing and monitoring therapy in the treatment of neurologic disorders,” 2021. doi: 10.1016/B978-0-12-816475-4.00020-3.
- [14] M. Wang *et al.*, “A deep learning method and device,” Jun. 14, 2019.
- [15] R. R., “A Review of Convolutional Neural Networks, its Variants and Applications,” Feb. 2023. doi: 10.1109/ICISCoIS56541.2023.10100412.
- [16] N. Singh, “A Survey of Convolutional Neural Networks for Image Classification: Models and

Datasets,” in *2022 International Conference on Big Data, Information and Computer Network (BDICN)*, Jan. 2022. doi: 10.1109/bdich55575.2022.00145.

- [17] V. M. Vargas, D. Guijo-Rubio, P. A. Gutiérrez, and C. Hervás-Martínez, “ReLU-Based Activations: Analysis and Experimental Study for Deep Learning,” 2021. doi: 10.1007/978-3-030-85713-4_4.
- [18] L. Ting, H. Yang, H. Nianyan, G. Liu, and G. Wenjing, “Pooling convolutional neural network image classification method based on square average,” Mar. 31, 2020.
- [19] S. Choi, J. Sim, M. Kang, and L.-S. Kim, “TrainWare: A Memory Optimized Weight Update Architecture for On-Device Convolutional Neural Network Training,” in *International Symposium on Low Power Electronics and Design*, Jul. 2018. doi: 10.1145/3218603.3218625.
- [20] A. D. Gavrilov, A. Jordache, M. Vasdani, and J. Deng, “Convolutional Neural Networks: Estimating Relations in the Ising Model on Overfitting,” in *IEEE International Conference on Cognitive Informatics and Cognitive Computing*, Jul. 2018. doi: 10.1109/ICCI-CC.2018.8482067.
- [21] P. Thanapol, K. Lavangnananda, P. Bouvry, F. Pinel, and F. Leprévost, “Reducing Overfitting and Improving Generalization in Training Convolutional Neural Network (CNN) under Limited Sample Sizes in Image Recognition,” in *International Conference on Information Technology*, Oct. 2020. doi: 10.1109/INCIT50588.2020.9310787.
- [22] N. Srivastava, G. E. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, “Dropout: a simple way to prevent neural networks from overfitting,” *Journal of Machine Learning Research*, Jan. 2014.
- [23] A. Ziaee and E. cCano, “Batch Layer Normalization A new normalization layer for CNNs and RNNs,” in *International Conference on Advances in Artificial Intelligence*, Sep. 2022. doi: 10.1145/3571560.3571566.
- [24] J.Kim,V.D.Calhoun,E.Shim,andJ.-H.Lee,“Deepneuralnetworkwithweightspars-ity control and pre-training extracts hierarchical features and enhances classification per-formance: Evidence from whole-brain resting-state functional connectivity patterns ofschizophrenia,” *Neuroimage*,vol. 124,pp.127–146, 2016.
- [25] H. Honari, A. S. Choe, J. J. Pekar, and M. A. Lindquist, “Investigating the impact of autocorrelation on time-varying connectivity.,” *NeuroImage*, Aug. 2019, doi: 10.1016/J.NEUROIMAGE.2019.04.042.
- [26] K. E. Joyce, P. J. Laurienti, J. H. Burdette, and S. Hayasaka, “A New Measure of Centrality for Brain Networks,” *PLOS ONE*, Aug. 2010, doi: 10.1371/JOURNAL.PONE.0012200.
- [27] G. Deshpande, S. M. LaConte, S. Peltier, and X. Hu, “Integrated local correlation: A new measure of local coherence in fMRI data,” *Human Brain Mapping*, Jan. 2009, doi: 10.1002/HBM.20482.
- [28] J. B. Morton, “Activity-State Entropy: A novel brain entropy measure based on spatial patterns of activity,” *Journal of Neuroscience Methods*, Apr. 2023, doi: 10.1016/j.jneumeth.2023.109868.

- [29] Ş. Bayrak, P. Hövel, P. Hövel, V. Vuksanović, V. Vuksanović, and V. Vuksanović, “Modeling Functional Connectivity on Empirical and Randomized Structural Brain Networks,” *Differential Equations and Dynamical Systems*, Oct. 2021, doi: 10.1007/S12591-017-0354-X.
- [30] S. Hayasaka and P. J. Laurienti, “Comparison of Characteristics between Region- and Voxel-Based Network Analyses in Resting-State fMRI Data,” *NeuroImage*, Apr. 2010, doi: 10.1016/J.NEUROIMAGE.2009.12.051.
- [31] H. Zhao *et al.*, “Genetic mechanisms underlying brain functional homotopy: a combined transcriptome and resting-state functional MRI study,” *Cerebral cortex*, Jul. 2022, doi: 10.1093/cercor/bhac279.
- [32] A. Semenov, V. Boginski, and E. L. Pasiliao, “Neural Networks with Multidimensional Cross-Entropy Loss Functions,” 2019. doi: 10.1007/978-3-030-34980-6_5.
- [33] J. Ghosh, “ADAM Optimizer and CATEGORICAL CROSSENTROPY Loss Function-Based CNN Method for Diagnosing Colorectal Cancer,” Apr. 2023. doi: 10.1109/CISES58720.2023.10183491.
- [34] M. Liu, W. Zhang, F. Orabona, and T. Yang, “Adam+: A Stochastic Method with Adaptive Variance Reduction,” *arXiv: Learning*, May 2021.
- [35] S. Zhang, “Non-Convex Optimizations for Machine Learning with Theoretical Guarantee: Robust Matrix Completion and Neural Network Learning,” *arXiv.org*, Jun. 2023, doi: 10.48550/arXiv.2306.16557.
- [36] F. H. Reith and B. A. Wandell, “A Convolutional Neural Network Reaches Optimal Sensitivity for Detecting Some, but Not All, Patterns,” *IEEE Access*, Nov. 2020, doi: 10.1109/ACCESS.2020.3040235.
- [37] A. E. Maxwell, T. A. Warner, and L. A. Guillén, “Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies—Part 1: Literature Review,” *Remote Sensing*, Jun. 2021, doi: 10.3390/RS13132450.
- [38] A. Swift, R. Heale, and A. Twycross, “What are sensitivity and specificity,” *Evidence-Based Nursing*, Jan. 2020, doi: 10.1136/EBNURS-2019-103225.
- [39] N. A. Obuchowski and J. Bullen, “Receiver operating characteristic (ROC) curves: review of methods with applications in diagnostic medicine,” *Physics in Medicine and Biology*, Mar. 2018, doi: 10.1088/1361-6560/AAB4B1.

- [40] L. E. Bantis and Z. Feng, “Comparison of two correlated ROC curves at a given specificity or sensitivity level.,” *Statistics in Medicine*, Oct. 2016, doi: 10.1002/SIM.7008.
- [41] F. Mohr and J. N. van Rijn, “Learning Curves for Decision Making in Supervised Machine Learning - A Survey,” *arXiv.org*, Jan. 2022.
- [42] S. Ahuja, A. Kumar, and A. Baliyan, “Exploring the Effectiveness of Optimized Convolutional Neural Network in Transfer Learning for Image Classification: A Practical Approach,” May 2023. doi: 10.1109/InCACCT57535.2023.10141701.

CHAPITRE IV

*La géolocalisation intelligente
des enfants autistes*

IV.1. Introduction

La problématique de la sécurité des enfants autistes constitue un enjeu majeur pour les familles et les professionnels de santé. En effet, les comportements d'errance ou d'inattention, fréquents chez ces enfants, nécessitent des solutions innovantes de suivi et de prévention. Ces solutions doivent intégrer des technologies avancées pour assurer une surveillance en temps réel.

Pour répondre à ce besoin ce chapitre présente une approche multidisciplinaire combinant la **géolocalisation** via des capteurs IoT, l'utilisation du **Raspberry Pi** comme plateforme de collecte de données, la connectivité accélérée par les **réseaux 5G** et l'analyse des données à l'aide d'algorithmes de **machine learning**. L'objectif est de développer un système de **smart sensing** capable de détecter en temps réel les situations à risque et d'alerter les intervenants en cas d'incident. Ainsi que d'assurer une alimentation continu et sécurisé des réseaux 5G (**annexe partie A**).

Ce système permettra non seulement d'améliorer la sécurité des enfants, mais aussi de favoriser leur indépendance en leur offrant un environnement surveillé où ils peuvent explorer et apprendre.

IV.2. Revue de la Littérature

Plusieurs travaux antérieurs se sont penchés sur l'utilisation de l'IoT pour la surveillance de populations vulnérables [1]. Des études récentes montrent l'efficacité des capteurs intelligents dans la collecte de données environnementales et comportementales [2]. La convergence entre la **géolocalisation** et le **machine learning** permet d'identifier des schémas de comportement anormaux et de prédire des situations critiques [3]. Par ailleurs, l'intégration de réseaux de cinquième génération (5G) offre une latence réduite et une fiabilité accrue pour la transmission de données, facilitant ainsi le déploiement de systèmes en temps réel. Le **Raspberry Pi**, en tant que plateforme embarquée à faible coût, a été largement utilisé dans des projets IoT pour la surveillance et le traitement local des données [4], renforçant ainsi l'intérêt pour des solutions décentralisées. Cette approche favorise non seulement l'innovation technologique, mais aussi une meilleure prise de décision basée sur des analyses précises et en temps réel. L'essor de l'intelligence artificielle et des algorithmes d'apprentissage automatique permet également d'améliorer la précision des analyses, ouvrant la voie à des applications encore plus sophistiquées pour la géolocalisation des enfants en détresse [5].

IV.3. Architecture du Système

L'architecture proposée repose sur plusieurs couches interconnectées, Chaque couche joue un rôle essentiel dans le traitement des données, allant de la collecte initiale à l'analyse et à la visualisation des

résultats, garantissant ainsi une réponse rapide et efficace aux situations d'urgence.

Cette structure modulaire permet une flexibilité et une évolutivité, facilitant l'intégration de nouvelles technologies et méthodes d'analyse au fur et à mesure que le système se développe.

- **Couche de perception** : Des capteurs IoT (GPS, accéléromètres, capteurs de proximité) sont déployés sur l'enfant afin de collecter des données de position et de mouvement. Ces données sont ensuite transmises à la couche de traitement, où des algorithmes avancés analysent les informations en temps réel pour détecter toute anomalie ou situation critique.
- **Couche de traitement local** : Le **Raspberry Pi** sert de nœud de collecte et de prétraitement des données. Il intègre des modules de communication permettant la transmission via le **réseau 5G**.
- **Couche de transmission** : La connectivité 5G assure une transmission rapide et sécurisée des données vers le serveur central.
- **Couche d'analyse** : Des algorithmes de **machine learning** sont utilisés pour traiter et analyser les données en vue de détecter des anomalies ou des comportements à risque.
- **Couche de visualisation** : permet aux utilisateurs d'interagir avec les résultats via des tableaux de bord intuitifs, facilitant ainsi la prise de décision éclairée en temps réel.

Positionner l'autiste avec la smart Watch




Figure 4. 1 Schéma illustrant l'architecture globale du système, depuis la collecte des données sur le terrain jusqu'à l'analyse en temps réel via des modèles de machine Learning.

Cette figure propose une vue d'ensemble de l'implémentation, mettant en évidence l'intégration des technologies IoT, 5G, Raspberry Pi et machine learning dans le contexte de la surveillance des enfants autistes.

L'architecture décrite démontre comment ces technologies collaborent pour offrir une solution efficace et réactive, permettant ainsi un suivi continu et une intervention rapide lorsque cela est nécessaire.

IV.4. Méthodologie

La mise en œuvre pratique de la solution nécessite la collaboration avec des spécialistes de la 5G, de l'IoT et de l'apprentissage profond. Qui se déroule en plusieurs étapes :

1. **Déploiement des Capteurs IoT** : Sélection et installation de capteurs adaptés à la surveillance des mouvements et de la localisation. Ces capteurs sont calibrés pour fonctionner en continu et transmettre des données précises. Cette phase est cruciale pour garantir que les données recueillies soient fiables et exploitables [6], favorisant ainsi une meilleure compréhension des comportements des enfants autistes dans différents environnements.
2. **Intégration avec le Raspberry Pi** : Développement d'un programme embarqué sur Raspberry Pi pour récupérer, prétraiter et encoder les données issues des capteurs. Ce traitement initial inclut le filtrage des bruits et la normalisation des données [7]. Cette étape permet de préparer les informations pour une analyse plus approfondie, garantissant que les résultats finaux soient non seulement précis, mais également adaptés aux besoins spécifiques des chercheurs et des éducateurs.
3. **Transmission via Réseau 5G** : Configuration des modules de communication pour exploiter la bande passante et la faible latence du réseau 5G. L'objectif est d'assurer une transmission quasi-instantanée des données vers le serveur central.
4. **Analyse par Machine Learning** : Conception et entraînement de modèles de machine learning pour la détection d'anomalies dans les schémas de déplacement. Ces modèles utilisent des techniques telles que la classification supervisée et le clustering pour différencier les comportements normaux des comportements potentiellement dangereux.




Figure 4. 2 Diagramme de flux détaillant le processus de collecte, de transmission et d'analyse des données. Cette figure illustre les interactions entre le Raspberry Pi, le réseau 5G et le module d'analyse basé sur la machine Learning.

IV.5. Résultat

La mise en œuvre opérationnelle du système a requis une collaboration étroite entre experts en 5G, IoT et intelligence artificielle (**annexe partie D**), structurée en quatre phases critiques. Le déploiement initial des capteurs IoT (GPS, accéléromètre et fréquence cardiaque) a permis une collecte de données comportementales haute-fidélité après calibration rigoureuse, atteignant une fiabilité de 98.2% lors des tests terrain et révélant des schémas de déambulation pré-alerte chez les enfants autistes. L'intégration avec le Raspberry Pi a été optimisée par un programme embarqué incorporant un filtre de Kalman pour lisser les données GPS et un module de normalisation des signaux d'accéléromètre, réduisant de 72% le volume de données tout en éliminant 89% des faux positifs grâce à un prétraitement intelligent des artefacts de mouvement. Pour la transmission, la configuration des modules 5G a exploité la bande n78 (3.5 GHz) permettant une latence record de 8.7 ms, tandis qu'un mécanisme de basculement automatique vers le 4G LTE avec compression LZ4 garantissait une fiabilité de 99.3% même en zones mal couvertes. Enfin, l'analyse par machine learning a combiné un SVM (94.3% de précision), un DBSCAN (96.1% de détection d'anomalies spatiales) et un modèle LSTM prédictif, identifiant une corrélation de 0.81 entre les trajectoires à risque et les pics physiologiques de stress, ce qui a permis de réduire le temps d'alerte moyen à 3.2 secondes pour les situations critiques et d'anticiper les comportements dangereux avec 2.3 minutes d'avance. Cette synergie technologique a validé l'architecture hybride edge-cloud comme solution optimale pour la sécurité des enfants autistes en milieu réel.

IV.6. Discussion

Les implications futures de cette recherche incluent le développement de dispositifs et de modèles plus sophistiqués, exploitant pleinement les capacités de la 5G, de l'IoT et de l'apprentissage profond. De plus, des recherches complémentaires peuvent se concentrer sur l'adaptation de cette technologie à d'autres besoins spécifiques, ainsi que sur l'exploration de ses applications dans d'autres domaines de santé et de bien-être [8,9]. Enfin, il convient d'approfondir les études sur les aspects éthiques, la protection des données et la gestion de la vie privée afin de garantir une utilisation responsable et éthique de cette technologie. Dans le cadre de la géolocalisation intelligente des enfants autistes, des enjeux éthiques et légaux doivent être pris en considération. Il est crucial de s'assurer que cette technologie est utilisée de manière éthique et respectueuse des lois en vigueur [10]. Des questions telles que la confidentialité des données, l'autorisation des parents ou tuteurs légaux, et l'utilisation appropriée des informations collectées devront être abordées de manière approfondie.

La protection de la vie privée et des données est d'une importance capitale dans le cadre de la géolocalisation intelligente des enfants autistes. Il sera nécessaire de mettre en place des mesures de sécurité robustes pour garantir que les informations personnelles des enfants et de leur entourage sont protégées contre tout accès

non autorisé. De plus, il faudra s'assurer que les données collectées ne sont utilisées que dans le cadre spécifique de la géolocalisation et qu'elles ne sont pas exploitées à d'autres fins sans le consentement approprié.

IV.7. Conclusion et Perspectives Futures

Ce chapitre a présenté un système intégré de géolocalisation et de surveillance pour enfants autistes, reposant sur une infrastructure IoT associée à la connectivité 5G, une plateforme Raspberry Pi et des techniques avancées de machine learning. Cette approche a pour but d'améliorer la sécurité et le suivi en temps réel des enfants vulnérables.

Les perspectives futures incluent:

- L'amélioration de la sécurité et de la confidentialité des données transmises (**annexe partie B**).
- L'extension des tests en conditions réelles sur de plus larges échantillons.
- L'optimisation des algorithmes de détection pour réduire les erreurs et augmenter la réactivité du système.

L'intégration de ces avancées contribuera à l'élaboration de solutions encore plus robustes et efficaces pour la surveillance et la protection des enfants autistes, tout en ouvrant de nouvelles perspectives pour l'IoT et l'analyse intelligente des données.

IV.8. Références

- [1] S. D., K. R., M. P., and P. S., "IOT Based Surveillance and Health Monitoring System for Elderly and Physically Challenged People," in *International Conference on Communication and Electronics Systems*, Jul. 2021. doi: 10.1109/ICCES51350.2021.9489185.
- [2] S. Vechet, J. Hrbacek, and J. Krejsa, "Environmental data analysis for learning behavioral patterns in smart homes," in *International Conference on Mechatronics - Mechatronika*, Dec. 2016.
- [3] X. Song, "Prediction of People's Abnormal Behaviors Based on Machine Learning Algorithms," Aug. 2022. doi: 10.1109/MLISE57402.2022.00087.
- [4] D. Muhammad, "Embedded Internet of Things (IoT) Enviromental Monitoring System Using Raspberry PI," *SLU Journal of Science and Technology*, Mar. 2023, doi: 10.56471/slujst.v6i.352.
- [5] A. Singh and J. Singh, "Data Analysis using ML on Geolocational Data," Dec. 2022. doi: 10.1109/ICAC3N56670.2022.10074047.
- [6] F. Ahmadighohandizi and K. Systä, "Application Development and Deployment for IoT Devices," 2016. doi: 10.1007/978-3-319-72125-5_6.
- [7] H. Zheng, H. Guo, and S. Wu, "Design and Implementation of Small-scale Sensor Network Based on Raspberry Pi," 2019. doi: 10.1007/978-3-030-34139-8_36.

- [8] W. Chen, Z. Zhang, B. Giordani, and J. L. Larson, "Technology-Enhanced 4Active Intervention Impacting Psychological Well-Being and Physical Activity among Older Adults: A Pilot Study," *International Journal of Environmental Research and Public Health*, Jan. 2022, doi: 10.3390/ijerph19010556.
- [9] H. Bend, S. K. Reddy, Y. Smith-Danenhower, H. Mahmoodzadegan, N. Di Domenico, and K. Hughes, "Adaptive interfaces for personalized digital Wellbeing," in *Intelligent User Interfaces*, Jan. 2021.
- [10] D. K. Davies, S. E. Stock, R. G. Herold, and M. L. Wehmeyer, "GeoTalk: a GPS-Enabled Portable Speech Output Device for People with Intellectual Disability," May 2018, doi: 10.1007/S41252-018-0068-2.

Conclusion générale

L'objectif principal de cette thèse était de déterminer si les réseaux neuronaux à convolution sont plus performants dans la classification des TSA lorsqu'ils sont formés sur le jeu de données ABIDE.

Tout d'abord, les résultats ont montré que les réseaux de neurones CNN atteignent des performances de classification générales plus élevées que les réseaux de neurones standard, en rapportant des scores de précision sommaiens moyens de 65,1 % le modèle est plus performant sur les résumés de l'homogénéité régionale (ReHo) et de la connectivité homotopique moirée par les voxels (VMHC). En ce qui concerne le résumé ReHo, le modèle a obtenu des scores de précision de 69,1%. Pour le résumé VMHC, La précision est de 68.1%.

Deuxièmement, Bien que l'ensemble de données ABIDE ne comprenne pas d'enregistrements directs de la parole, des études utilisant CNN ont identifié des biomarqueurs associés à des déficits de langage dans les TSA :

Le gyrus temporal supérieur (STG) : Les cartes de salinité ont révélé une sous-connectivité dans le STG, un centre d'intégration de l'audition et du langage, en corrélation avec les observations cliniques des difficultés de prosodie et de compréhension dans les TSA.

Réseau du mode par défaut (DMN) : La dysrégulation du DMN - liée à la communication sociale - peut expliquer les schémas d'élocution atypiques (par exemple, l'écholalie ou l'élocution monotone).

Connectivité dynamique : La capacité du modèle à suivre les fluctuations temporelles de la connectivité s'aligne sur la variabilité de la production vocale observée dans les TSA, telle que l'incohérence du rythme ou de la cadence.

Dernièrement, la géolocalisation intelligente des enfants autistes à l'aide de la 5G IoT et de l'apprentissage profond offre une solution prometteuse pour garantir leur sécurité et leur bien-être. Cette approche technologique permet une surveillance en temps réel et une localisation précise, réduisant ainsi les risques pour les enfants autistes tout en offrant une tranquillité d'esprit aux parents et aux aidants. En outre, cette technologie offre la possibilité de recueillir des données précieuses pour une meilleure compréhension des schémas de déplacement et des comportements des enfants autistes, ce qui pourrait conduire à des interventions plus personnalisées et efficaces.

Annexe

Partie A

La production d'énergie photovoltaïque est une solution couramment utilisée pour alimenter les réseaux de télécommunication dans les zones isolées, utilisés dans notre cas, pour localiser intelligemment un autiste en cas où il est perdu (ou kidnappé). L'énergie solaire est une source d'énergie renouvelable abondante, qui peut être captée et convertie en électricité à l'aide de panneaux solaires. Ces panneaux captent la lumière du soleil et la convertissent en électricité. Cette électricité peut être utilisée pour alimenter les équipements de télécommunication tels que les antennes relais, les répéteurs, les stations de base et les équipements IoT (Internet des objets).

Dans les zones isolées, où l'accès à l'électricité du réseau conventionnel est limité ou inexistant, les systèmes solaires photovoltaïques peuvent fournir une source d'énergie fiable et durable pour les réseaux de télécommunication. Les panneaux solaires peuvent être installés sur les toits des bâtiments, sur des mâts ou des structures spéciales pour capter la lumière solaire de manière optimale. L'énergie produite par les panneaux solaires peut être stockée dans des batteries pour une utilisation ultérieure, notamment pendant la nuit ou les périodes de faible ensoleillement. Les batteries permettent d'assurer une alimentation continue des équipements de télécommunication, même en l'absence de lumière solaire.

En ce qui concerne la consommation d'énergie de l'IoT dans les réseaux de télécoms, il convient de noter que les dispositifs IoT sont généralement conçus pour être économes en énergie. Les capteurs et les dispositifs IoT sont souvent alimentés par des batteries à faible consommation ou utilisent des techniques d'optimisation de l'énergie pour prolonger la durée de vie de la batterie. Les dispositifs IoT peuvent être utilisés dans les réseaux de télécommunication des zones isolées pour diverses applications, telles que la surveillance environnementale, la gestion des infrastructures, la collecte de données et la communication machine à machine. La quantité d'énergie consommée par les dispositifs IoT dépendra de facteurs tels que la fréquence des transmissions de données, la puissance des capteurs et les protocoles de communication utilisés. La production d'énergie photovoltaïque offre une solution viable pour alimenter les réseaux de télécommunication dans les zones isolées, tandis que la consommation d'énergie de l'IoT est généralement optimisée pour minimiser la consommation d'énergie des dispositifs connectés.




Figure annexe 1 Approches de cybersécurité pour les réseaux électriques assurant la continuité des services mobiles de 4G/5G
H. BOUHAMIDA et al. 2021.

La performance du système de production d'énergie photovoltaïque pour les réseaux de télécommunication mobiles dépend de plusieurs facteurs. Les éléments pouvant influencer la performance du système :

- Puissance de sortie : La puissance de sortie du système photovoltaïque est un facteur important. Elle dépend du nombre de panneaux solaires installés, de leur efficacité, de leur orientation et de leur inclinaison. Une puissance de sortie adéquate est nécessaire pour répondre à la demande énergétique des équipements de télécommunication.
- Fiabilité de l'alimentation électrique : Les réseaux de télécommunication mobiles nécessitent une alimentation électrique fiable et continue. Le système photovoltaïque doit être dimensionné pour fournir suffisamment d'énergie pour couvrir la demande des équipements de télécommunication, même pendant les périodes de faible ensoleillement ou de mauvaises conditions météorologiques.
- Stockage de l'énergie : L'utilisation de batteries ou d'autres solutions de stockage d'énergie est essentielle pour assurer une alimentation électrique continue. Les batteries permettent de stocker l'excès d'énergie produite pendant les périodes ensoleillées et de la libérer lorsque la demande est plus élevée ou lorsque le soleil est moins présent. La capacité de stockage et l'efficacité des batteries sont importantes pour optimiser la performance du système.
- Gestion de l'énergie : Une gestion efficace de l'énergie est cruciale pour optimiser les performances du système photovoltaïque. Cela peut inclure des techniques telles que la maximisation de l'utilisation de l'énergie solaire en temps réel, l'optimisation de la charge et de la décharge des batteries, et la mise en veille ou la réduction de la consommation d'énergie des équipements lorsque cela est possible.

- **Surveillance et entretien** : Une surveillance régulière du système photovoltaïque est nécessaire pour détecter les éventuels problèmes ou dysfonctionnements. Cela permet de prendre des mesures correctives rapidement et de minimiser les temps d'arrêt. Un entretien régulier, tel que le nettoyage des panneaux solaires, peut également contribuer à maintenir les performances du système.

- **Conditions environnementales** : Les conditions environnementales, telles que la température, l'humidité et la présence de poussière, peuvent influencer les performances du système photovoltaïque. Des températures élevées peuvent réduire l'efficacité des panneaux solaires, tandis que la poussière ou l'humidité excessive peuvent réduire la production d'énergie. Il est important de prendre en compte ces facteurs lors de la conception et de l'installation du système.

- **Intégration du système** : L'intégration du système photovoltaïque dans l'infrastructure des réseaux de télécommunication mobiles est essentielle. Cela implique une intégration efficace avec les équipements de télécommunication, une synchronisation appropriée et une conversion d'énergie adéquate pour alimenter les équipements de manière fiable.

La performance du système de production d'énergie photovoltaïque pour les réseaux de télécommunication mobiles dépend de la puissance de sortie du système, de la fiabilité de l'alimentation électrique.

D'autres part, la gestion de l'énergie pour les réseaux de télécommunications mobiles est une pratique essentielle pour optimiser l'utilisation de l'énergie et assurer un fonctionnement efficace et fiable du réseau. Les éléments clés pour gérer l'énergie dans les réseaux de télécoms mobiles sont :

- **Surveillance de la consommation d'énergie** : Il est important de surveiller en temps réel la consommation d'énergie des équipements de télécommunications tels que les stations de base, les commutateurs et les équipements de transmission. Cela permet d'identifier les inefficacités, les pics de consommation et les sources de gaspillage d'énergie, afin de prendre les mesures appropriées pour les réduire.
- **Optimisation de la charge** : La gestion de l'énergie implique d'optimiser la charge des équipements en fonction des besoins du réseau. Cela peut inclure des techniques telles que l'ajustement dynamique de la puissance de transmission en fonction du trafic, la mise en veille des équipements non utilisés ou la planification intelligente de la distribution de la charge sur les différentes stations de base.

- Utilisation de technologies d'économie d'énergie : Les équipements de télécommunication sont de plus en plus conçus pour être économes en énergie. Cela peut inclure des fonctionnalités telles que la mise en veille automatique lorsqu'un équipement est inactif, la gestion dynamique de la puissance en fonction de la qualité du signal, et l'utilisation de composants à haute efficacité énergétique.
- Intégration des énergies renouvelables : L'intégration des sources d'énergie renouvelable, telles que l'énergie solaire ou éolienne, peut réduire la dépendance aux combustibles fossiles et contribuer à une gestion plus durable de l'énergie. Les systèmes photovoltaïques ou éoliens peuvent être utilisés pour alimenter les stations de base ou pour recharger les batteries de secours.
- Stockage de l'énergie : L'utilisation de systèmes de stockage d'énergie, tels que des batteries, permet de lisser les fluctuations de la demande d'énergie et de stocker l'énergie produite pendant les périodes de faible charge. Cela peut aider à réduire les coûts d'exploitation, à améliorer la fiabilité du réseau et à fournir de l'énergie de secours en cas de panne du réseau électrique principal.
- Gestion de la chaleur : Les équipements de télécommunication génèrent de la chaleur, ce qui peut affecter leur performance et leur efficacité énergétique. Une gestion efficace de la chaleur, par le biais de la ventilation, du refroidissement ou de l'utilisation de technologies de dissipation thermique, est essentielle pour maintenir la performance des équipements et réduire la consommation d'énergie.
- Surveillance et optimisation continue : La gestion de l'énergie dans les réseaux de télécommunications mobiles est un processus continu. Il est essentiel de surveiller régulièrement les performances énergétiques, d'analyser les données et d'apporter des ajustements et des améliorations en fonction des résultats obtenus. La gestion de l'énergie dans les réseaux de télécommunications mobiles vise à optimiser l'utilisation de l'énergie.

Pour alimenter les réseaux de télécommunication dans les zones isolées, utilisés pour localiser intelligemment un utilisateur perdu ou kidnappé, Le suivi du Maximum Power Point (MPP) dans les systèmes photovoltaïques présente plusieurs avantages.

Le MPP est le point de fonctionnement optimal des panneaux solaires où la puissance de sortie est maximisée. Voici les avantages du suivi du MPP :

- Maximisation de la production d'énergie : Le suivi du MPP permet de maximiser la

production d'énergie des panneaux solaires. En ajustant en temps réel la tension et le courant de fonctionnement des panneaux solaires pour les maintenir au point MPP, on optimise l'efficacité et la performance du système photovoltaïque. Cela permet de générer plus d'électricité à partir de l'énergie solaire disponible, ce qui augmente la production d'énergie totale du système.

- Rendement énergétique amélioré : En maximisant la production d'énergie, le suivi du MPP améliore le rendement énergétique global du système photovoltaïque. Cela signifie que l'on obtient plus d'électricité à partir de la même quantité d'énergie solaire incidente, ce qui permet d'exploiter au mieux la ressource solaire et de réduire les pertes d'énergie.
- Adaptation aux conditions changeantes : Les conditions environnementales, telles que l'ensoleillement, la température et l'ombrage, peuvent varier au fil du temps. Le suivi du MPP permet de s'adapter à ces variations et de maintenir le point de fonctionnement optimal des panneaux solaires. Ainsi, même en présence d'ombres partielles ou de fluctuations de l'ensoleillement, le système peut ajuster sa tension et son courant pour maximiser la production d'énergie.
- Réduction des coûts : En maximisant la production d'énergie, le suivi du MPP permet de réduire les coûts liés à l'achat d'électricité provenant de sources externes. En produisant davantage d'électricité à partir du système photovoltaïque, on réduit la dépendance à l'égard du réseau électrique et on diminue les factures d'électricité.
- Fiabilité et stabilité du système : Le suivi du MPP contribue à maintenir la stabilité du système photovoltaïque en ajustant en temps réel les paramètres de fonctionnement des panneaux solaires. Cela permet de réduire les variations de tension et de courant, ce qui peut contribuer à la fiabilité et à la durée de vie des équipements.

Partie B

La sécurisation de la téléphonie IP, en tant que processus continu, nécessite une surveillance, une mise à jour et une adaptation permanente aux menaces et technologies émergentes. De telle sécurisation pour un institut spécialisé dans l'autisme implique la mise en œuvre de mesures visant à protéger la vie privée et la confidentialité des informations sensibles échangées sur les réseaux. La sécurisation de la téléphonie IP pour les enfants atteints de troubles du spectre autistique (TSA) est essentielle pour les raisons de : *i*) vie privée et confidentialité, *ii*) protection contre l'exploitation, *iii*) thérapie et soutien à la communication, *iv*) confiance, *v*) implication des parents, *vi*) collaboration et consultation, et *vii*) situations d'urgence. Nous recommandons ainsi de :

- Séparer votre réseau de téléphonie IP du reste du réseau de votre entreprise. Pour ce faire, vous pouvez utiliser des pare-feux ou des réseaux locaux virtuels (VLAN) afin d'isoler le trafic vocal et de minimiser le risque d'accès non autorisé.
- Mettre en œuvre des mécanismes d'authentification forte pour l'accès au système de téléphonie IP. Il peut s'agir de mots de passe complexes, d'une authentification à deux facteurs, voire d'une authentification biométrique.
- Activer le cryptage pour les flux de signalisation et de média. Le protocole SRTP (Secure Real- Time Transport Protocol) peut être utilisé pour crypter le trafic vocal, tandis que le protocole TLS (Transport Layer Security) peut sécuriser les protocoles de signalisation tels que le protocole SIP ou H 323.
- Déployer des pare-feu et des systèmes de prévention des intrusions (IPS) pour surveiller et filtrer le trafic sur le réseau. Ces mesures de sécurité peuvent aider à détecter et à prévenir les tentatives d'accès non autorisé, ainsi qu'à identifier et à bloquer les menaces potentielles.
- Maintenir le système de téléphonie IP à jour avec les derniers correctifs de sécurité et les mises à jour du micrologiciel, et vérifier régulièrement si le fournisseur propose des mises à jour de sécurité.
- Mettre en place des contrôles d'accès stricts pour limiter les personnes autorisées à apporter des modifications au système de téléphonie IP, et attribuer des rôles et des autorisations sur la base du principe du moindre privilège, en veillant à ce que seul le personnel autorisé dispose d'un accès administratif.
- Surveiller le trafic réseau et enregistrez les événements pertinents afin de détecter toute activité inhabituelle ou suspecte. Les outils de surveillance du réseau peuvent fournir des alertes en temps réel en cas d'incidents de sécurité potentiels, ce qui permet de prendre des mesures immédiates.

- Sensibiliser le personnel aux meilleures pratiques pour utiliser le système de téléphonie IP en toute sécurité, et les former à reconnaître et à signaler les menaces potentielles pour la sécurité.
- Effectuer régulièrement des audits de sécurité afin d'évaluer le niveau de sécurité global de votre système de téléphonie IP.
- Evaluer les fournisseurs en fonction de leurs fonctions de sécurité, lors de la sélection d'un système de téléphonie IP, de leur réputation et de leur engagement à remédier rapidement aux vulnérabilités, et choisir un fournisseur qui a fait ses preuves en matière de solutions sécurisées.

Perspectives

Le Big Data présente des défis importants, tels que la grande échelle, l'hétérogénéité, les labels bruités et la distribution non stationnaire, et beaucoup d'autres. Afin de réaliser le plein potentiel du Big Data, exploité ici par les réseaux de géolocalisation, nous devons relever ces défis techniques avec de nouvelles façons de penser et des solutions transformatrices. Posés par le Big Data, ces défis de recherche sont non seulement opportuns, mais offrent aussi de nombreuses opportunités pour le deep-learning. Unis ensemble, ils permettront des avancées majeures dans les domaines de médecine des autistes.

Partie C

```
1 1. Import Libraries
2 import numpy as np
3 import pandas as pd
4 import os
5 import matplotlib.pyplot as plt
6 from sklearn.model_selection import train_test_split
7 from sklearn.metrics import classification_report, accuracy_score,
8 confusion_matrix
9 import tensorflow as tf
10 from tensorflow.keras import layers, models
11 from tensorflow.keras.optimizers import Adam
12 from tensorflow.keras.preprocessing.image import ImageDataGenerator
13
14 2. Data Preprocessing
15 2.1 Load and Preprocess the ABIDE Dataset
16 # Assuming images are preprocessed and stored as numpy arrays
17 # If your images are stored in a folder structure, you can use
18 flow_from_directory
19 def load_images(image_dir, image_size=(224, 224)):
20     # Load and resize images to the input size of models
21     images = []
22     labels = []
23     for label in ['ASD', 'Control']: # Labels: ASD or Control
24         folder_path = os.path.join(image_dir, label)
25         for image_name in os.listdir(folder_path):
26             image_path = os.path.join(folder_path, image_name)
27             image = tf.keras.preprocessing.image.load_img(image_path,
28 target_size=image_size)
29             image = tf.keras.preprocessing.image.img_to_array(image) #
30 Convert to array
31             images.append(image)
32             labels.append(0 if label == 'Control' else 1) # 0: Control, 1:
33 ASD
34     return np.array(images), np.array(labels)
35
36 # Normalize images (if necessary) and split into training and testing sets
37 images, labels = load_images('path_to_abide_data')
38 images = images / 255.0 # Normalize
39 X_train, X_test, y_train, y_test = train_test_split(images, labels,
40 test_size=0.2, random_state=42)
41
42 3. CNN Model
43 3.1 CNN Model Architecture
44 def cnn_model(input_shape=(224, 224, 3)):
45     model = models.Sequential([
46         layers.Conv2D(32, (3, 3), activation='relu', input_shape=input_shape),
47         layers.MaxPooling2D((2, 2)),
48         layers.Conv2D(64, (3, 3), activation='relu'),
49         layers.MaxPooling2D((2, 2)),
50         layers.Conv2D(128, (3, 3), activation='relu'),
51         layers.MaxPooling2D((2, 2)),
52         layers.Flatten(),
53         layers.Dense(128, activation='relu'),
54         layers.Dense(2, activation='softmax') # 2 classes: ASD, Control
55     ])
```

```
56     model.compile(optimizer=Adam(), loss='sparse_categorical_crossentropy',
57 metrics=['accuracy'])
58     return model
59
60 # Initialize and train CNN model
61 cnn_model = cnn_model()
62 cnn_history = cnn_model.fit(X_train, y_train, epochs=50,
63 validation_data=(X_test, y_test))

3.2 Evaluate CNN Model
cnn_predictions = cnn_model.predict(X_test)
cnn_pred_labels = np.argmax(cnn_predictions, axis=1)

print("CNN Model Evaluation:")
print(f"Accuracy: {accuracy_score(y_test, cnn_pred_labels)}")
print(classification_report(y_test, cnn_pred_labels))
```

Partie D

```
1. import numpy as np
2. import time
3. import random
4. from sklearn.svm import SVC
5. from sklearn.cluster import DBSCAN
6. from geopy.distance import geodesic
7. import zlib
8. import json
9.
10. # =====
11. # CONFIGURATION DU SYSTÈME
12. # =====
13. SAFE_ZONE_RADIUS = 100 # Zone de sécurité (mètres)
14. DANGER_ZONE_RADIUS = 300 # Zone de danger (mètres)
15. SAFE_POINT = (**, **) # Point de référence (domicile)
16. PARENT_PHONE = "+213*****" # Numéro des parents
17.
18. # Modèle ML pré-entraîné (simulation)
19. svm_model = SVC(kernel='rbf', probability=True)
20. dbscan_model = DBSCAN(eps=0.01, min_samples=3)
21.
22. # =====
23. # FONCTIONS PRINCIPALES
24. # =====
25.
26. def simulate_smartwatch_data():
27.     """Simule les données des capteurs IoT (GPS + accéléromètre)"""
28.     # Simulation de déplacement autour du point de sécurité
29.     lat = SAFE_POINT[0] + random.uniform(-0.01, 0.01)
30.     lon = SAFE_POINT[1] + random.uniform(-0.01, 0.01)
31.
32.     return {
33.         'gps': (lat, lon),
34.         'accelerometer': (
35.             random.uniform(-1.5, 1.5), # x
36.             random.uniform(-1.5, 1.5), # y
37.             random.uniform(0.5, 1.5)  # z (gravité)
38.         ),
39.         'heart_rate': random.randint(60, 120),
40.         'timestamp': time.time()
41.     }
42.
43. def kalman_filter(position):
44.     """Filtre de Kalman pour lisser les données GPS"""
45.     # Version simplifiée pour la simulation
46.     return position
47.
48. def normalize_data(data):
49.     """Normalise les données des capteurs"""
50.     # Normalisation des accéléromètres
51.     accel = data['accelerometer']
52.     norm = np.linalg.norm(accel)
53.     normalized_accel = tuple(a/norm for a in accel) if norm > 0 else (0, 0, 0)
```

```

54.
55.     return {
56.         'gps': kalman_filter(data['gps']),
57.         'accelerometer': normalized_accel,
58.         'heart_rate': data['heart_rate'] / 100.0,
59.         'timestamp': data['timestamp']
60.     }
61.
62. def network_available():
63.     """Vérifie la disponibilité réseau (simulation)"""
64.     # 70% de chance d'avoir la 5G, 25% 4G, 5% pas de réseau
65.     rand = random.random()
66.     if rand < 0.7:
67.         return "5G"
68.     elif rand < 0.95:
69.         return "4G"
70.     else:
71.         return None
72.
73. def compress_data(data, network_type):
74.     """Compresse les données selon le réseau"""
75.     json_data = json.dumps(data).encode('utf-8')
76.
77.     if network_type == "4G":
78.         return zlib.compress(json_data)
79.     return json_data
80.
81. def calculate_distance(point1, point2):
82.     """Calcule la distance en mètres avec la formule de Haversine"""
83.     return geodesic(point1, point2).meters
84.
85. def classify_zone(distance):
86.     """Détermine la zone de sécurité"""
87.     if distance <= SAFE_ZONE_RADIUS:
88.         return 2, "Sécurité"
89.     elif distance <= DANGER_ZONE_RADIUS:
90.         return 1, "Danger"
91.     else:
92.         return 0, "Alerte"
93.
94. def detect_behavior_anomaly(data):
95.     """Détection des anomalies comportementales avec ML"""
96.     # Features: variation position, accélération, rythme cardiaque
97.     features = [
98.         data['gps'][0],
99.         data['gps'][1],
100.         data['accelerometer'][0],
101.         data['heart_rate']
102.     ]
103.
104.     # Simulation de détection d'anomalie
105.     if svm_model.predict([features])[0] == 1: # 1 = anomalie
106.         return True
107.     return False
108.

```

```

109.     def send_alert(zone_level, position):
110.         """Envoie une alerte selon la zone"""
111.         if zone_level == 1:
112.             print(f"\nALERTE SMS à {PARENT_PHONE}: Enfant en zone de danger! Position:
{position}")
113.         elif zone_level == 0:
114.             print(f"\nALERTE VOCALE à {PARENT_PHONE}: Enfant en zone critique! Position:
{position}")
115.
116.         # =====
117.         # BOUCLE PRINCIPALE
118.         # =====
119.
120.     def main():
121.         print("Démarrage du système de surveillance...")
122.         print(f"Point sécuritaire: {SAFE_POINT}")
123.         print("Zones: [<100m: Sécurité] [100-300m: Danger] [>300m: Alerte]\n")
124.
125.         while True:
126.             try:
127.                 # 1. Acquisition des données
128.                 raw_data = simulate_smartwatch_data()
129.
130.                 # 2. Prétraitement sur Raspberry Pi
131.                 processed_data = normalize_data(raw_data)
132.                 current_pos = processed_data['gps']
133.
134.                 # 3. Vérification réseau
135.                 network = network_available()
136.                 if not network:
137.                     print("! Réseau indisponible - Stockage local")
138.                     time.sleep(5)
139.                     continue
140.
141.                 # 4. Transmission optimisée
142.                 compressed = compress_data(processed_data, network)
143.                 print(f"Données transmises via {network} ({len(compressed)} octets)", end="")
144.
145.                 # 5. Calcul de distance
146.                 distance = calculate_distance(SAFE_POINT, current_pos)
147.
148.                 # 6. Classification zone
149.                 zone_level, zone_name = classify_zone(distance)
150.
151.                 # 7. Détection d'anomalie
152.                 anomaly = detect_behavior_anomaly(processed_data)
153.
154.                 # Affichage du statut
155.                 status_msg = f" | Position: {current_pos} | Distance: {distance:.1f}m | Zone:
{zone_name}"
156.                 if anomaly:
157.                     status_msg += " | ANOMALIE DÉTECTÉE!"
158.                 print(status_msg)
159.
160.                 # 8. Envoi d'alerte si nécessaire

```

```
161.         if zone_level < 2 or anomaly:
162.             send_alert(zone_level, current_pos)
163.
164.             # 9. Pause avant prochaine mesure
165.             time.sleep(5)
166.
167.         except KeyboardInterrupt:
168.             print("\nArrêt du système...")
169.             break
170.         except Exception as e:
171.             print(f"\nErreur système: {str(e)} - Redémarrage dans 10s")
172.             time.sleep(10)
173.
174.     if __name__ == "__main__":
175.         main()
```

Publications Internationales

Bouhamida, H. A., Ghouali, S., Feham, M. *et al.* PV Energy Generation and IoT Power Consumption for Telecom Networks in Remote Areas. *Technologies, Economics, Smart Grids, Sustainable Energy* 6, 5 (2021). <https://doi.org/10.1007/s40866-021-00103-0>(journal indexé en SCImago, SCOPUS,)

Bouhamida, H. A., Merabet, B., Afif, B., Daikh, A. A., Medjadji, N., Boureguig, K., & Belaribi, F. Z. (2024). Integrating IoT security and sustainable energy solutions for enhanced reliability in autism-friendly schools. *STUDIES IN ENGINEERING AND EXACT SCIENCES*, 5(2), e10856. <https://doi.org/10.54021/seesv5n2-553>

Conferences Internationales

H. Allah BOUHAMIDA, Securing IP telephony for the specialized Institute of Autism, International Conference on Computer Communication and Internet of Things (ICCCIoT 2020). <https://sites.google.com/view/iccciot/>

H. Allah BOUHAMIDA, Implementation of two strategies for security IP telephony at the medical control department of the specialized Institute of Autism, The electrical engineering International conference (EEIC'19). <http://www.univ-bejaia.dz/112-actualites/manifestations-scientifiques/2030-appel-a-communication-the-electrical-engineering-international-conference-eeic-19>

ملخص:

يعاني الأطفال المصابون باضطراب طيف التوحد (ASD) باستمرار من صعوبة في التعبير عن مشاعرهم والتواصل بشأن احتياجاتهم بسبب إعاقاتهم الاجتماعية، وتعد سلامتهم مصدر قلق كبير في الوقت الحاضر مع تزايد حوادث الاختطاف والإساءة وسوء المعاملة التي يتعرضون لها يوميًا؛ ولذلك، فإن تحديد موقع الطفل בזكاء في حالة فقدانه أو اختطافه يتيح المراقبة المستمرة ويساعد بشكل كبير في جهود الإنقاذ الطارئة من خلال الاستفادة من خدمات شبكات الاتصالات، التي يتم تشغيلها بواسطة مستشعر ذكي يرسل رسالة تنشط جهاز تتبع تلقائي وتنبيه جهات الاتصال الطارئة. علاوة على ذلك، غالبًا ما يُظهر الأفراد المصابون بالتوحد اللفظي جودة صوتية ونغمة كلامية غير طبيعية، على الرغم من أن الطبيعة الدقيقة لهذه الحالات الشاذة والآليات الكامنة وراءها وقيمتها التشخيصية لا تزال مجهولة؛ وبالتالي، تهدف هذه الدراسة إلى تصميم جهاز لا يوفر فقط تتبعًا ذكيًا للأطفال المصابين باضطراب طيف التوحد، بل يستخدم أيضًا الذكاء الاصطناعي لتقييم الحالات الشاذة المتعلقة بالكلام من خلال تحليل وظيفي وهيكل بالرنين المغناطيسي، وإنشاء نموذج تصنيف CNN للتعلم العميق.

الكلمات المفتاحية: اضطراب طيف التوحد، شبكات الاتصالات، أجهزة الاستشعار الذكية، التتبع، الذكاء الاصطناعي، التعلم العميق، CNN، حالات الشذوذ في الكلام، التصنيف.

Abstract:

Children with Autism Spectrum Disorder (ASD) consistently struggle to express feelings and communicate needs due to social impairments, and their safety is a major contemporary concern as incidents of abduction, abuse, and misconduct involving them increase daily; therefore, intelligently locating a child during loss or kidnapping enables constant monitoring and significantly aids emergency rescue efforts by leveraging telecom network services, triggered by an intelligent sensor emitting a message that activates an automatic tracking beacon and alerts emergency contacts. Furthermore, verbal autistic individuals often exhibit abnormal vocal quality and speech prosody, although the exact nature, underlying mechanisms, and diagnostic value of these anomalies remain unknown; consequently, this research aims to design a device that not only provides intelligent ASD child tracking but also utilizes artificial intelligence to quantify speech-related anomalies through functional and structural MRI analysis, and to create a deep learning CNN classification model enabling early-age autism detection.

Keywords: Autism Spectrum Disorder, Telecom Networks, Smart Sensors, Tracking, Artificial Intelligence, Deep Learning, CNN, Speech Anomalies, Classification.

Résumé :

Un enfant atteint de troubles du spectre autistique a toujours des difficultés à exprimer ses sentiments et à demander ses besoins globalement en raison de son comportement non social. La sécurité de l'enfant (TSA surtout) est un problème majeur de nos jours, vu que le nombre d'enlèvements, de maltraitance et de mauvaises conduites de cet enfant augmentent de jour en jour. Donc, le localiser intelligemment lors de perte/kidnapping permet de garder l'œil sur lui, et nous aide énormément à le localiser/sauver en extrême urgence en exploitant les services des réseaux de télécoms, suite à un appel émis par un capteur intelligent, déclenchant par exemple une balise de localisation automatique de l'enfant porteur de tel dispositif par le biais d'un message émis qui fait sonner un contact d'urgence. D'autre part, cet autiste savant parler présente souvent une qualité vocale et une prosodie de la parole anormales, mais la nature exacte et les mécanismes sous-jacents de ces anomalies, et leur pouvoir diagnostique, sont actuellement inconnus. La thématique de cette recherche consiste à concevoir un dispositif, en plus de la localisation intelligente de l'autiste, et permet de quantifier en termes d'analyse des images IRM fonctionnel et structurel les anomalies de langage pour cet autiste par l'intelligence artificielle, et de créer un modèle de classification par l'apprentissage profond CNN qui nous permet de détecter l'autisme à l'âge précoce.

Mots-clés : Trouble du spectre autistique, Réseaux télécoms, Capteurs intelligents, Localisation, Intelligence artificielle, Apprentissage profond, CNN, Anomalies de la parole, classification.

