

République Algérienne Démocratique et Populaire  
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



Université Saâd Dahlab Blida 1  
Faculté des sciences  
Département d'informatique

---

Mémoire de fin d'études  
Pour l'obtention du diplôme de Master  
Option : Ingénierie des Logiciels

---

# Système Décisionnel Intelligent basé sur Deep learning pour l'amélioration de la résilience dans les Smart Grids

---

*Réalisé par :*

BERKAT Siham  
BOUGUERNOUT Imene

*Encadré par :*

Dr. KHEDIRI Abderrazak

*Soutenu le 7 juillet 2022, Devant le jury composé de :*

BALA MAHFOUD	MCB - Président
NASRI AHLEM	MCB - Examinatrice
KHEDIRI ABDERRAZAK	MAB - Promoteur

2021 / 2022

## Dédicaces

A mes chers parents, pour tous leurs sacrifices, leur amour, leur tendresse, leur soutien et leurs prières tout au long de mes études,  
A ma sœur, pour leur encouragement permanent, et leur soutien moral,  
A mon frère, pour leur appui et leur encouragement,  
A toute ma famille pour leur soutien tout au long de mon parcours universitaire,  
Que ce travail soit l'accomplissement de vos vœux tant allégués, et le fruit de votre soutien infaillible,  
Merci d'être toujours là pour moi.

## SIHAM

Je dédie ce travail en premier lieu à mes parents qui m'ont toujours soutenu dans mes choix et m'ont encouragé dans mes études, leurs soutiens dans les moments d'euphorie comme dans les moments de quiétude. Que dieu les bénissent et leur accorde une longue vie pleine de satisfaction.  
Sans pour autant oublier mes grands-parents pour leurs encouragements, leurs soutiens et leurs conseils. Que dieu leur accorde une longue vie.  
Mes soeurs de m'avoir écouté aussi patiemment.  
Je tiens à remercier mon binôme Sihem et mes copines, pour leur amitié, leur soutien inconditionnel et leur encouragement. Ainsi que, Mes cousines, toute ma famille et tous ceux qui ont participé et m'ont encouragé de près ou de loin.

## IMENE

## Remerciement

Notre remerciement va en premier lieu à ALLAH le tout puissant de nous avoir donné la foi et de nous avoir permis d'en arriver là.

Nous tenons à remercier particulièrement notre promoteur Monsieur Abderrazak KHEDIRI pour son encadrement et pour l'intérêt qu'il a manifesté à notre travail.

Nous remercierons très sincèrement, les membres de jury d'avoir bien voulu accepter de faire partie de la commission d'examineur.

Nous adressons également nos remerciements, à tous nos enseignants, qui ont contribué à notre formation tout au long de nos années d'études.

Nous tenons également à remercier tous nos collègues de promotion que nous avons eu le plaisir de les côtoyer pendant cette période de formation.

Nous remercierons tous ceux qui ont contribué de près ou de loin à la réalisation de ce travail.

# Liste des acronymes

AD	Arbre de Décision
AHP	Analytic Hierarchy Process
ANN	Artificial Neural Networks
CBR	Case Based Reasoning
CNN	Convolutional Neural Networks
DBN	Deep Belief Network
DL	Deep Learning
DM	Data Mining
EAG	État Actuel Grid
EFG	État Final Grid
EIG	État Initial Grid
ES	Exponential Smoothing
FR	Facteur de Risque
FC	Fully Connected Layer
FN	Faux Négatif
FP	Faux Positif
GPU	Graphical processing unit
GRM	Generic Recovery Milestone

HAN	Home Area Network
IA	Intelligence Artificielle
IDSS	Intelligent Decision Support System
KNN	K-nearest neighbor
LSTM	Long Short-Term Memory
MA	Moving Average
MCDA	Multiple-Criteria Decision Analysis
ML	Machine Learning
MLP	Multilayer Perceptron
NA	Nombre des attributs
NAN	Neighborhood Area Networ
PA	Poids d'attribut
PMU	Phasor Measurement Unit
RBM	Restricted Boltzmann Machine
RL	Reinforcement Learning
RNN	Recurrent Neural Network
ROC	Receiver Operating Characteristic
RW	Random Walk
SAD	Systèmes d'Aide à la Décision

S-CNN	Smoothed Convolutional Neural Network
SED	Seuil état dangereux
SEE	Seuil état extrêmement dangereux
SES	Simple Exponential Smoothing
SG	Smart Grid
SGBD	Système de Gestion de Base de Données
SIAD	Système Intelligent d'Aide à la Décision
SMA	Système Multi-Agent
STI	Système de Transport Intelligent
SVM	Support Vector Machines
TIC	Techniques de l'Information et de la Communication
TPU	Tensor Processing Unit
VN	Vrai Négatif
VP	Vrai Positif
WAN	Wide Area Network

## Résumé

Le smart grid est le nouveau concept dans le domaine énergétique qui rend les villes plus intelligentes, avec sa combinaison du numérique et des énergies renouvelables dans les réseaux de distribution d'électricité. Il a été construit pour répondre aux besoins du réseau électrique traditionnel en matière de contrôle de la demande croissante en électricité, ainsi qu'intègre les consommateurs dans le processus de distribution pour qu'ils puissent être des consomm-acteurs.

L'objectif des smart grids est d'intégrer une solution informatique dans le réseau afin de distribuer l'énergie d'une façon durable et économique, en garantissant la sécurité des données personnel, aussi le smart grid a la capacité de surveiller les perturbations électriques.

Malgré tous ses avantages, il reste vulnérable et comporte des points faibles. Parmi les points faibles du smart grid c'est qu'il n'a pas la capacité de gérer toutes les perturbations, ce qui complique la situation pour les opérateurs et ça pourrait prendre beaucoup du temps afin de rétablir les pannes. Cela souligne l'importance de mettre en place un système décisionnel capable de prévoir les pannes de courant éminentes, afin d'améliorer la résilience du réseau électrique, et aider les opérateurs à prendre les mesures nécessaires afin d'éviter les pertes économiques éventuelles.

Ce mémoire a pour objectif de proposer une architecture d'un système décisionnel basé sur le modèle de deep learning smoothed convolutional neural network (S-CNN), entraîné sur une base de données historique réelle, afin d'améliorer la résilience des smart grids. Ce modèle est destiné à prévoir les pannes de courant électriques, en déclenchant une alarme pour que les opérateurs prennent les décisions nécessaires afin de prévenir les pannes.

**Mot clé :** Systèmes décisionnel intelligent, smart grid, résilience, deep learning, villes intelligentes.

## Abstract

The smart grid is the new concept in the energy field that makes cities smarter, with its combination of digital and renewable energy in the electricity distribution networks. It was built to meet the needs of the traditional power grid in controlling the growing demand for electricity as well as integrating consumers into the distribution process so they can be consumer-actors.

The objective of the smart grid is to integrate an IT solution into the network in order to distribute energy in a sustainable and economical way by guaranteeing the security of personal data, also that the smart grid has the ability to monitor electrical disturbances.

Despite all its advantages, it remains vulnerable and has many weak points, including the fact that the smart grid does not have the capacity to manage all disturbances, which complicates the situation for operators and could take a long time to restore the outages. This underscores the importance of implementing a decision-making system capable of predicting prominent power outages in order to improve the resilience of the power grid and help operators take the necessary measures to avoid potential economic losses.

The objective of this thesis is to propose an architecture of a decision support system based on the deep learning smoothed convolutional neural network (S-CNN) model, trained on a real historical database, to improve the resilience of smart grids. This model is designed to predict power outages, triggering an alarm so that operators can make the necessary decisions to prevent outages.

**Keyword :** Intelligent decision systems, smart grid, resilience, deep learning, smart cities.

## ملخص

الشبكة الذكية هي المفهوم الجديد في مجال الطاقة والذي يجعل المدن أكثر ذكاءً ، بمزيجها من الطاقات الرقمية والمتجددة في شبكات توزيع الكهرباء. تم بناؤها لتلبية احتياجات شبكة الكهرباء التقليدية من حيث التحكم في الطلب المتزايد على الكهرباء بالإضافة إلى دمج المستهلكين عملية التوزيع حتى يصبحوا منتجين ومستهلكين في نفس الوقت.

الهدف من الشبكة الذكية هو دمج حل تكنولوجيا المعلومات في الشبكة من أجل توزيع الطاقة بطريقة مستدامة واقتصادية من خلال ضمان أمن البيانات الشخصية ، كما أن الشبكة الذكية لديها القدرة على مراقبة الاضطرابات الكهربائية

على الرغم من كل مزاياها ، إلا أنها تظل ضعيفة ولديها نقاط ضعف. من بين نقاط الشبكة الذكية أنها لا تملك القدرة على إدارة جميع الاضطرابات ، مما يعقد الوضع للمشغلين وقد يستغرق الأمر وقتاً طويلاً لاصلاح الاعطال ، هذا يسلط الضوء على أهمية تنفيذ نظام اتخاذ القرار، القادر على التنبؤ بانقطاع التيار الكهربائي الوشيك من أجل تحسين مرونة الشبكة الكهربائية ، ومساعدة المشغلين على اتخاذ التدابير اللازمة لتجنب الخسائر الاقتصادية المحتملة تهدف هذه الأطروحة إلى اقتراح بنية لنظام اتخاذ القرار بناءً على نموذج التعلم العميق

(S-CNN)

هذا النموذج مدرب على قاعدة بيانات تاريخية حقيقية ، من أجل تحسين مرونة الشبكات الذكية ، يهدف هذا النموذج إلى التنبؤ بانقطاع التيار الكهربائي ، مما يؤدي إلى إطلاق إنذار للمشغلين لاتخاذ القرارات اللازمة لمنع الانقطاعات

**الكلمات المفتاحية :** أنظمة اتخاذ القرار الذكية ، الشبكة الذكية ، المرونة ، التعلم العميق ، المدن الذكية

# Liste des tableaux

1.1	Concept relatifs à la vile intelligente . . . . .	7
1.2	Comparaison entre un réseau électrique traditionnel et intelligent . . . . .	15
2.1	Le rôle de différents acteurs d'aide à la décision . . . . .	27
2.2	Comparaison entre les décisions programmables et non programmables . . . . .	27
2.3	Les différentes problématiques traitées par MCDA . . . . .	28
2.4	Classement de travaux de recherches . . . . .	40
4.1	Répartition du Dataset. . . . .	66
4.2	Paramètres utilisés pour KNN . . . . .	68
4.3	Résultat obtenue avec KNN. . . . .	68
4.4	Paramètres utilisés pour SVM . . . . .	69
4.5	Résultat obtenue avec SVM. . . . .	69
4.6	Paramètres utilisés pour CNN . . . . .	70
4.7	résultat obtenue avec CNN. . . . .	70
4.8	Paramètres utilisés pour LSTM . . . . .	71

4.9	Résultat obtenue avec LSTM. . . . .	71
4.10	Paramètres utilisés pour CNN-LSTM . . . . .	73
4.11	Résultat obtenue avec CNN-LSTM. . . . .	73
4.12	Paramètres utilisés pour MLP . . . . .	74
4.13	résultat obtenue avec MLP. . . . .	74
4.14	Résultat obtenue avec S-CNN. . . . .	75
4.15	Paramètres utilisé et leurs signification . . . . .	76
4.16	Résumé de l'expérimentation . . . . .	79
4.17	Comparaison entre diffèrent modèles. . . . .	80

# Table des figures

1.1	Facteurs d'intelligence dans une ville . . . . .	8
1.2	Les composants de la ville intelligente . . . . .	10
1.3	Architecture des smart grids . . . . .	13
1.4	Modèle général du Smart grid . . . . .	17
1.5	Les composants de la résilience du réseau électrique intelligent	21
2.1	Le processus de décision . . . . .	26
2.2	Architecture d'un SAD . . . . .	31
2.3	Data science comme un domaine multidisciplinaire . . . . .	33
2.4	La relation entre IA, ML, DL . . . . .	34
2.5	Schéma illustratif de DL avec plusieurs couches . . . . .	37
3.1	Architecture proposée . . . . .	45
3.2	Architecture d'un CNN . . . . .	48
3.3	Couche convolutive . . . . .	50
3.4	Couche de mise en commun (pooling) . . . . .	51
3.5	Couche entièrement connectée . . . . .	52
3.6	Vérification de coupure . . . . .	58

4.1	Logo de Python . . . . .	61
4.2	Logo de TensorFlow . . . . .	62
4.3	Logo de NumPy . . . . .	63
4.4	Logo de Pandas . . . . .	63
4.5	Logo de Matplotlib . . . . .	63
4.6	Logo de Scikit-learn . . . . .	64
4.7	Logo de Keras . . . . .	64
4.8	Google colab . . . . .	65
4.9	Courbe CNN . . . . .	70
4.10	Courbe LSTM . . . . .	72
4.11	Courbe CNN-LSTM . . . . .	73
4.12	Courbe MLP . . . . .	75
4.13	Courbe S-CNN . . . . .	76
4.14	Courbe ROC . . . . .	79
4.15	Résultats obtenus . . . . .	80

# Table des matières

Liste des acronymes	III
Liste des tableaux	X
Table des figures	XII
Introduction générale	1
<b>1 Contexte : Ville intelligente et Smart grids</b>	<b>5</b>
1.1 Introduction . . . . .	6
1.2 Ville intelligente (Smart City) . . . . .	6
1.2.1 Définition . . . . .	6
1.2.2 Les facteurs qui rendent une ville plus intelligente . . .	6
1.2.3 Les principaux composants d'une ville intelligente . . .	9
1.3 Smart Grid : Qu'est-ce que c'est exactement ? . . . . .	13
1.3.1 Caractéristiques d'un réseau électrique intelligent . . .	14
1.3.2 Concept d'un Smart grid : . . . . .	14

1.3.3	Différence entre un réseau électrique traditionnel et intelligent . . . . .	14
1.3.4	Enjeux des smart grid . . . . .	15
1.4	Modèle général du Smart grid . . . . .	16
1.4.1	Technologies des smart grids . . . . .	17
1.4.2	Compteurs intelligents (smart meters) : . . . . .	19
1.4.3	Microgrid . . . . .	19
1.4.4	Résilience des smart grids . . . . .	20
1.4.5	Défaillance en cascade dans les smart grid . . . . .	21
1.4.6	Délestage électrique . . . . .	22
1.5	Conclusion . . . . .	22
<b>2</b>	<b>État de l'art : Systèmes décisionnels</b>	<b>23</b>
2.1	Introduction . . . . .	24
2.2	Aide à la décision . . . . .	24
2.2.1	Décision . . . . .	25
2.2.2	Processus d'aide à la décision . . . . .	25
2.2.3	Les acteurs d'aide à la décision . . . . .	26
2.2.4	Décision du groupe . . . . .	27
2.2.5	Topologies de la décision . . . . .	27
2.2.6	Aide à la décision multicritère . . . . .	28
2.2.7	Typologie de problème traité par MCDA : . . . . .	28
2.2.8	Les principales méthodes multicritères . . . . .	29
2.3	Systèmes d'aide à la décision (Decision Support System) . . . . .	30

2.3.1	Les taxonomies des systèmes décisionnels . . . . .	30
2.3.2	Architectue des SAD . . . . .	30
2.3.3	Fonctionnalité des SAD . . . . .	31
2.4	Les systèmes intelligents d'aide à la décision (SIAD) . . . . .	31
2.4.1	Intelligence artificielle . . . . .	32
2.4.2	Science de données (Data science) . . . . .	32
2.5	SIAD et résilience de smart grid . . . . .	33
2.5.1	L'apprentissage automatique . . . . .	33
2.5.2	L'apprentissage profond (Deep learning) . . . . .	36
2.5.3	Systèmes multi agents . . . . .	37
2.5.4	Apprentissage par renforcement profond . . . . .	38
2.5.5	Prise de décision d'un groupe . . . . .	39
2.6	Synthèse . . . . .	39
2.6.1	Utilisation de méthodes d'aide à la décision multi critères . . . . .	40
2.6.2	Utilisation de techniques de data mining . . . . .	40
2.6.3	Utilisation de SMA . . . . .	41
2.6.4	Utilisation de méthodes de décision du groupe . . . . .	41
2.7	Conclusion . . . . .	41

### **3 Contribution : Système décisionnel pour l'amélioration de la résilience du réseau électrique intelligent** **43**

3.1	Introduction . . . . .	44
-----	------------------------	----

3.2	Architecture d'un système décisionnel pour l'amélioration de la résilience dans les smart grids : . . . . .	44
3.2.1	Description de l'architecture : . . . . .	46
3.3	Conclusion : . . . . .	59
<b>4</b>	<b>Évaluation expérimentale des propositions</b>	<b>60</b>
4.1	Introduction . . . . .	61
4.2	les outils et bibliothèques utilisés . . . . .	61
4.2.1	outils logiciels . . . . .	61
4.2.2	outils matériels . . . . .	65
4.3	Expérimentations . . . . .	65
4.3.1	Dataset . . . . .	65
4.4	Mesure de performance des modèles : . . . . .	66
4.4.1	Justesse (Accuracy) : . . . . .	66
4.4.2	Précision : . . . . .	66
4.4.3	Rappel (Recall) : . . . . .	67
4.4.4	F1 Score : . . . . .	67
4.5	Algorithmes et résultats : . . . . .	67
4.5.1	k plus proches voisins (KNN) : . . . . .	67
4.5.2	Support Vector Machine (SVM) : . . . . .	68
4.5.3	CNN : . . . . .	70
4.5.4	LSTM : . . . . .	71
4.5.5	CNN-LSTM : . . . . .	72
4.5.6	MLP : . . . . .	74

4.5.7	S-CNN : . . . . .	75
4.6	Explication des méthodes utilisées : . . . . .	77
4.6.1	Optimisateur "Adam" : . . . . .	77
4.6.2	Fonction d'activation : . . . . .	77
4.6.3	La Régularisation : . . . . .	78
4.6.4	Epoch : . . . . .	78
4.6.5	Batch Size : . . . . .	78
4.7	Prédiction et évaluation des modèles : . . . . .	79
4.7.1	la courbe ROC : . . . . .	79
4.7.2	Discussion : . . . . .	81
4.8	Conclusion . . . . .	82
<b>Conclusion générale et perspectives</b>		<b>83</b>
4.9	Conclusion générale . . . . .	83
4.10	Perspectives . . . . .	84

# Introduction générale

## contexte du travail

Tout au long de ces années, le monde a vécu un immense développement dans le domaine technologique, économique et énergétique. En outre, les constructions en masse partout dans le monde, implique une demande accrue et de plus en plus croissante en énergie électrique.

En effet, avec l'avancement technologique que notre monde a connu par rapport aux années passées, le réseau électrique actuel ne suffit plus à subvenir aux besoins de la population, avec l'accroissement des besoins en énergie, les réseaux électriques intelligents ont été développés pour répondre à ces besoins en intégrant les énergies renouvelables.

Les réseaux électriques intelligents (smart grids) révolutionnent l'infrastructure actuelle du réseau électrique en intégrant les technologies de l'information et de la communication, permettant aux fournisseurs et aux consommateurs de transporter, surveiller, contrôler, et prévoir efficacement la consommation d'énergie [1].

N'ayant moins, bien que ces Smart Grids représentent l'avenir de demain pour le domaine électrique, en étant des réseaux résilient qui sert à surveiller les perturbations électriques afin d'éviter les pannes et ils possèdent la capacité de revenir à l'état normal, mais ils ne restent pas fiables à 100% pour éviter les pannes.

De ce fait, nous avons trouvé une solution qui consiste en un système décisionnel qui détecte la présence d'une panne afin d'améliorer la résilience des smart grids, et ce qui aide les opérateurs à prendre les mesures nécessaires avant la survenue des pannes.

## **Problématique**

Afin de permettre l'analyse des données, la surveillance des pannes, le stockage de l'énergie et même la capacité de réagir en temps réel à différents changements et dommages, les réseaux électriques intelligents nécessitent l'intégration de technologies de l'information et de la communication, telles que des logiciels. Il ne s'agit pas de prétendre que les pannes d'électricité ne se produiront pas avec un réseau intelligent ; en fait, des pannes peuvent se produire même dans des conditions météorologiques dangereuses et en cas de panne d'équipement.

Bien que plusieurs approches et techniques, telles que les systèmes de contrôle et d'acquisition de données (SCADA), aient été proposées, l'anticipation des pannes, la réparation des réseaux électriques endommagés et l'amélioration de la résilience sont considérées depuis longtemps comme des questions importantes nécessitant une étude plus approfondie.

Plusieurs questions se posent :

- Serait-il possible d'améliorer la résilience dans les smart grids davantage et assurer un système tolérant aux pannes ?
- Comment assurer une bonne prise de décision pour les opérateurs, les clients et les autorités publics ?
- Comment permettre aux utilisateurs de prendre les mesures nécessaires contre les coupures électriques ?

## **Motivation**

De nombreuses régions du monde, notamment l'Italie [2] et l'Amérique du Nord [3] en 2003, ont connu des coupures massives de courant. Autrefois la seule option était de construire des sources d'énergie supplémentaires.

Actuellement, il est conseillé de manipuler des réseaux plus sophistiqués pour résoudre les problèmes susmentionnés [4].

En raison de la vulnérabilité du système de distribution aux perturbations, des pannes de courant prolongées peuvent se produire. Ces perturbations peuvent provoquer des défaillances en cascade et entraîner d'éventuelles pertes financières pour les citoyens et les opérateurs [5]. Par conséquent, lorsque les centrales électriques ne peuvent pas fournir suffisamment d'énergie, ou même en cas de panne de courant, une mise à niveau des smart grids est nécessaire.

## **Objectif**

L'objectif de notre travail consiste à proposer un système décisionnel pour l'amélioration de la résilience des réseaux électriques intelligents, avec la prédiction des pannes électrique, cela aide les décideurs à prendre les mesures nécessaires avant la survenue des pannes pour diminuer les pertes économiques potentielles.

## **Organisation du mémoire**

Le présent travail articule en 4 chapitres :

### **Chapitre 1 : Contexte : Ville intelligente et Smart grids**

Dans ce chapitre nous présentons les Smart grids, ses caractéristiques, enjeux, technologie, la résilience dans les smart grids, les défaillances en cascade et le délestage électrique.

## **Chapitre 2 : Systèmes décisionnels**

Dans ce chapitre nous abordons la notion d'aide à la décision, ainsi que l'aide à la décision multicritère, Typologie de problème traité par MCDA, par la suite nous allons présenter les systèmes intelligents d'aide à la décision, ainsi que ses fonctionnalités, les différentes techniques utilisées par le SIAD dans les smart grids dans le but d'améliorer la résilience. Nous concluons par une synthèse.

## **Chapitre 3 : Contribution : Système décisionnel pour l'amélioration de la résilience du réseau électrique intelligent**

Dans ce chapitre, nous présentons notre architecture proposée du Système décisionnel pour améliorer la résilience du réseau électrique basé sur le modèle de deep learning « S-CNN » afin de prédire les coupures électriques et de déterminer le degré de danger dans le réseau électrique pour aider les opérateurs à prendre les mesures nécessaires.

## **Chapitre 4 : Évaluation expérimentale des propositions**

Dans ce chapitre, nous évoluons notre modèle proposé Smoothed convolution neural network entraîné par un jeu de données de série chronologique de coupure électrique historique, et valider leur efficacité dans la prédiction des pannes en faisons une comparaison avec différents techniques d'apprentissage automatique et du deep learning.

Ce mémoire sera clôturer par une conclusion générale qui résume les points principaux abordés et propose certaines perspectives envisagées pour l'amélioration de notre travail.

# Chapitre 1

Contexte : Ville intelligente et Smart grids

## 1.1 Introduction

Le réseau électrique intelligent (smart grid) est un composant essentiel des systèmes d'une ville intelligente (smart city), en particulier dans les régions urbaines à forte consommation d'énergie.

L'objectif principal d'un smart grid est la distribution, la production et la consommation d'énergie d'une manière efficace.

Dans ce chapitre, nous aborderons les généralités des réseaux électriques intelligents et la notion de la résilience dans les smart grids.

## 1.2 Ville intelligente (Smart City)

### 1.2.1 Définition

Une ville intelligente est un nouveau concept de développement urbain qui améliore la qualité de vie des citoyens en rendant les villes plus adaptatives et efficaces grâce à l'utilisation de nouvelles technologies basées sur un écosystème d'objets et de services [6].

### 1.2.2 Les facteurs qui rendent une ville plus intelligente

Pour déterminer tous les facteurs d'intelligence, nous devons d'abord examiner de plus près les concepts liées à la ville intelligente [7]. Le tableau 1.1 résume ces concepts.

Facteur	Concept
Technologie	Ville numérique(Digital city) Ville intelligente Ville ubiquitaire (Ubiquitous city) Ville filaire (Wired city) Ville hybride
Personnes	Ville créative Ville apprenante Ville humaine Ville de savoir(Knowledge city)
Communauté	Communauté intelligente (Smart community)

TABLE 1.1 – Concept relatifs à la vile intelligente [7]

Les facteurs essentiels d'une ville intelligente sont reclassés en trois catégories : La technologie (infrastructure matérielle et logicielle), les personnes (créativité, diversité et éducation) et les institutions (gouvernance et politique) [8].

La figure 1.1 représente les facteurs essentiels qui rendent une ville intelligente.

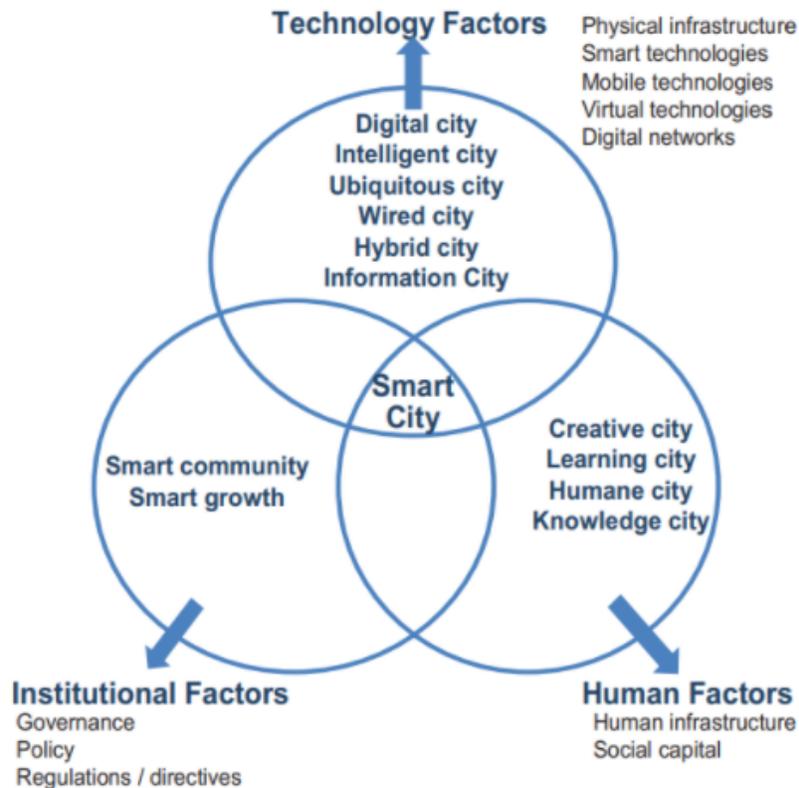


FIGURE 1.1 – Facteurs d’intelligence dans une ville [7]

**Les facteurs humains :** La ville intelligente dépend fortement de personnes intelligentes. L’idée de personnes intelligentes englobe un certain nombre de caractéristiques, notamment l’intérêt pour l’apprentissage tout au long de la vie, la diversité ethnique et socio-économique, la capacité d’adaptation, l’innovation, le cosmopolitisme ou l’ouverture d’esprit, et la participation aux affaires publiques [8].

**Les facteurs institutionnelles :** Le développement des villes intelligentes dépend fortement du soutien gouvernemental et des pratiques de gouvernance. Cette catégorie comprend une variété de facteurs institutionnels qui sont discutés en relation avec les initiatives de communauté intelligente ou de croissance intelligente. Ces facteurs institutionnels com-

prennent la gouvernance, le rôle du gouvernement et les relations entre le gouvernement et les organisations non gouvernementales, en plus des politiques de soutien. Un environnement administratif de soutien ( initiatives, structure et engagement ) doit être créé pour la ville intelligente [9].

**Les facteurs technologiques :** La technologie est le facteur le plus important pour qu'une ville soit intelligente, car elle utilise les TIC pour changer de manière significative et fondamentale la vie et le travail dans une ville. Bien qu'une ville intelligente ne puisse exister sans une infrastructure performante, celle-ci est une condition préalable. Il ne peut y avoir de ville intelligente sans un véritable engagement en faveur de la collaboration et de la coopération entre les organismes officiels, le secteur commercial, les écoles et la population. L'infrastructure et les applications informatiques sont essentielles [10].

### 1.2.3 Les principaux composants d'une ville intelligente

La figure 1.2 représente les principaux composants d'une ville intelligente.

Une ville intelligente est constituée d'un ensemble de composants clés indispensables. On ne peut pas imaginer une ville intelligente qui ne contienne pas au moins une partie de cet ensemble. Ces composants sont des systèmes intelligents spécifiques à un domaine [11].

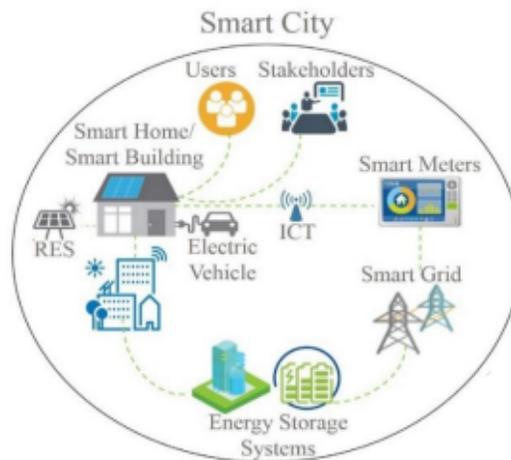


FIGURE 1.2 – Les composants de la ville intelligente [12]

### 1.2.3.1 Les systèmes de transport intelligents

Les systèmes de transport intelligents (STI) appliquent les technologies de l'information et de la communication aux transports, telles que les planificateurs d'itinéraires et les véhicules autonomes, pour rendre les déplacements plus sûrs, plus efficaces et plus durables [13].

### 1.2.3.2 Immotique (smart buildings)

Immotique ou smart building en anglais, est un bâtiment à haute efficacité énergétique. L'installation et l'utilisation de systèmes de technologie du bâtiment intégrés et à la pointe du progrès font partie de l'automatisation de l'immoque. Ces systèmes comprennent les systèmes de gestion des installations, les télécommunications, les systèmes d'utilisation et l'automatisation des bâtiments.

### 1.2.3.3 Les systèmes énergétiques intelligents

Les systèmes énergétiques intelligents sont définis comme une stratégie dans laquelle les réseaux intelligents d'électricité, de chaleur et de gaz sont connectés et coordonnés pour identifier les synergies entre eux, afin d'obtenir la meilleure solution pour chaque secteur, ainsi que pour l'ensemble du système énergétique [14].

Les systèmes énergétiques intelligents sont également considérés comme des systèmes énergétiques durables, rentables et sécurisés, qui intègrent et coordonnent la production, l'infrastructure et la consommation d'énergie renouvelable par le biais de services énergétiques, d'utilisateurs actifs et de technologies habilitantes [15].

#### **Les réseaux électriques intelligents (smart grid)**

L'essayiste américain Jeremy Rifkin a été le premier à parler de ce nouveau concept de "smart grid" dans son livre "The Third Industrial Revolution" [16].

Il définit un réseau électrique intelligent comme l'intégration de solutions informatiques complexes dans le réseau de distribution.

Ainsi, la combinaison à grande échelle du numérique et de l'énergie va générer un nouveau paradigme énergétique en permettant l'intégration des énergies renouvelables dans nos réseaux de distribution [16].

Le réseau est divisé en quatre sous-systèmes liés à différents niveaux de tension :

#### **Production**

La production d'énergie électrique implique la conversion de sources

d'énergie convertibles en énergie moyenne tension. Toute source d'énergie commutable peut être divisée en deux parties principales :

- Les sources d'énergie non renouvelables telles que le charbon, le mazout, les combustibles fossiles et l'énergie nucléaire.
- Les sources d'énergie renouvelables telles que l'énergie solaire, éolienne et hydroélectrique, la biomasse et l'énergie des vagues [17].

### **Transport et distribution**

Les réseaux de transport et de distribution (T&D) acheminent l'électricité des centrales jusqu'aux consommateurs à trois tensions différentes : très haute, haute et moyenne.

### **Consommation**

Les consommateurs d'électricité sont répartis en 4 secteurs principaux [18] :

1. Secteur résidentiel : Regroupe les logements unifamiliaux ou individuels et les logements collectifs.
2. Secteur commercial : comprends des organisations publiques et privées comme les installations gouvernementales et les équipements de prestation de services.
3. Secteur industriel : Comprends des industries telles que la fabrication, l'exploitation minière, l'agriculture et la construction.
4. Secteur des transports : La majorité de son énergie provient de la combustion directe de combustibles fossiles tels que l'essence, le diesel et le carburacteur. Certaines voitures, en revanche, dépendent de l'électricité fournie par le réseau. Ces véhicules comprennent les automobiles électriques alimentées par batterie et les voitures électriques hybrides rechargeables qui stockent l'énergie du réseau pendant qu'elles rechargent leurs batteries.

La figure 1.3 représente l'architecture des smart grids.

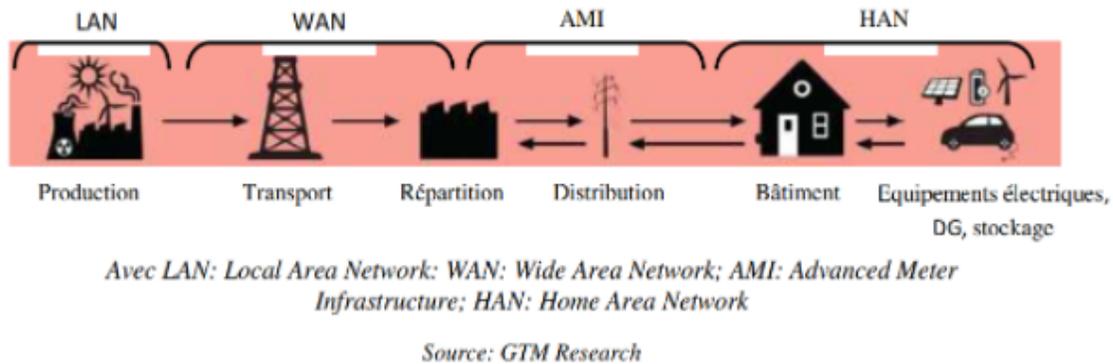


FIGURE 1.3 – Architecture des smart grids [19]

### 1.3 Smart Grid : Qu'est-ce que c'est exactement ?

Les réseaux électriques intelligents sont des réseaux qui peuvent être intégrés à un coût optimal le comportement de tous les utilisateurs qui s'y rapportent producteurs et consommateurs.

L'objectif des réseaux électriques intelligents est de produire et de distribuer l'énergie de manière plus efficace, économique et durable, tout en garantissant la sécurité d'approvisionnement. Pour ce faire, il intègre et interconnecte des technologies (produits et services) et des outils innovants toute sa chaîne de valeur, de la production d'énergie aux équipements consommateur.

Des capteurs et des équipements numériques de communication, de mesure et de protection sont utilisés pour interagir avec les centres de contrôle et de gestion afin de permettre cette intégration. Les consommateurs peuvent obtenir des informations fiables sur leur consommation d'énergie grâce aux réseaux intelligents, ils peuvent ainsi mieux surveiller et contrôler leur propre consommation [20].

### 1.3.1 Caractéristiques d'un réseau électrique intelligent

Un réseau électrique intelligent peut être défini selon les quatre caractéristiques suivantes [21] :

- **Flexibilité** : il peut gérer plus finement l'équilibre entre production et consommation.
- **Fiabilité** : il augmente l'efficacité et la sécurité du réseau.
- **Accessibilité** : il facilite l'intégration des énergies renouvelables sur le réseau.
- **Économiques** : il permet d'économiser de l'énergie et de réduire les coûts (de production et de consommation) grâce à une meilleure gestion des systèmes.

### 1.3.2 Concept d'un Smart grid :

La structure optimale du SG doit être développée pour le concept principal, en tenant compte [22] :

- Intégration des énergies renouvelables.
- Application de technologies innovantes, telles que les dispositifs de stockage d'énergie électronique de Puissance, Véhicules électriques.
- Utilisation des technologies de communication pour améliorer l'observabilité et la contrôlabilité du réseau.
- Développer des applications intelligentes pour les systèmes de protection notion d'automatisation.
- Haute sécurité de la production d'énergie et diverses informations liées à SG, conception de nouvelles structures de réseau, telles que les "micro-smart grids", réseau de transport avec stockage .

### 1.3.3 Différence entre un réseau électrique traditionnel et intelligent

Les réseaux électriques intelligents sont différents des réseaux traditionnels, le tableau 1.2 présente ces différences.

Réseau électrique traditionnel	Réseau électrique intelligent
Analogique	Numérique
Consommateur.	Consomm'acteur.
Production centralisée.	Production décentralisée.
Unidirectionnel.	Bidirectionnel.

TABLE 1.2 – Comparaison entre un réseau électrique traditionnel et intelligent [23]

**un consomm-acteur** est un consommateur, ainsi qui devient à son tour un producteur d'énergie en utilisant différentes techniques comme les panneaux solaires, etc [24].

### 1.3.4 Enjeux des smart grid

Le développement des réseaux électrique intelligents présente certains défis :

- **Enjeux environnementaux** : En intégrant de nouvelles formes d'énergies renouvelables, notamment les énergies décentralisées, tout en minimisant les impacts du changement climatique et les perturbations environnementales.
- **Enjeux industriels** : Matériaux et technologies actuels nécessaires pour accueillir cette nouvelle intelligence. En accédant à ce réseau d'innovation, il est nécessaire d'assurer la fonctionnalité de tous les éléments qui y jouent un rôle, de sorte que le développement, la modification, l'amélioration et l'aménagement sont nécessaires pour une utilisation correcte.
- **Enjeux économiques** : Par de nouvelles collaborations entre acteurs économiques clés dans la modernisation du secteur électrique, et par le rôle de l'État dans le développement du smart grid en tant que service public.
- **Enjeu sociétal** : Les consommateurs sont impliqués dans la gestion de leur consommation d'énergie grâce aux compteurs communicants, ainsi l'utilisateur interagit avec le réseau intelligent, un nouveau concept prend tout son sens le concept de consommateur [25].

## 1.4 Modèle général du Smart grid

Les smart grids vont assister à la migration des réseaux électriques à flux unidirectionnel à un réseau où l'électricité et l'information circulent dans les deux sens. La figure 1.4 représente un modèle général d'un réseau électrique intelligent. Il montre l'intégration des énergies renouvelables telles que les éoliennes et le photovoltaïque aux réseaux de transport moyenne tension et distribution basse tension. Outre les grandes usines de production, les consommateurs entrent également en jeu, tel que les centres commerciaux, maisons, véhicules électriques, grandes usines, etc.

Les consommateurs peuvent à leur tour devenir des producteurs d'énergie s'ils ont leur propre générateur. En plus du flux bidirectionnel de courant, il existe également un flux des informations plus efficaces sur la gestion de l'énergie. En raison de la nouvelle technologie d'information, les administrateurs réseaux trouveront et localisent facilement les défauts sur le réseau.

Le centre de contrôle du gestionnaire de réseau sera également informé à temps des besoins énergétiques des consommateurs, ils allouent alors la bonne quantité d'électricité. Par conséquent, le fonctionnement du réseau électrique intelligent repose sur la possibilité d'interaction entre les réseaux ou plusieurs entités passent par un réseau de communication [20].

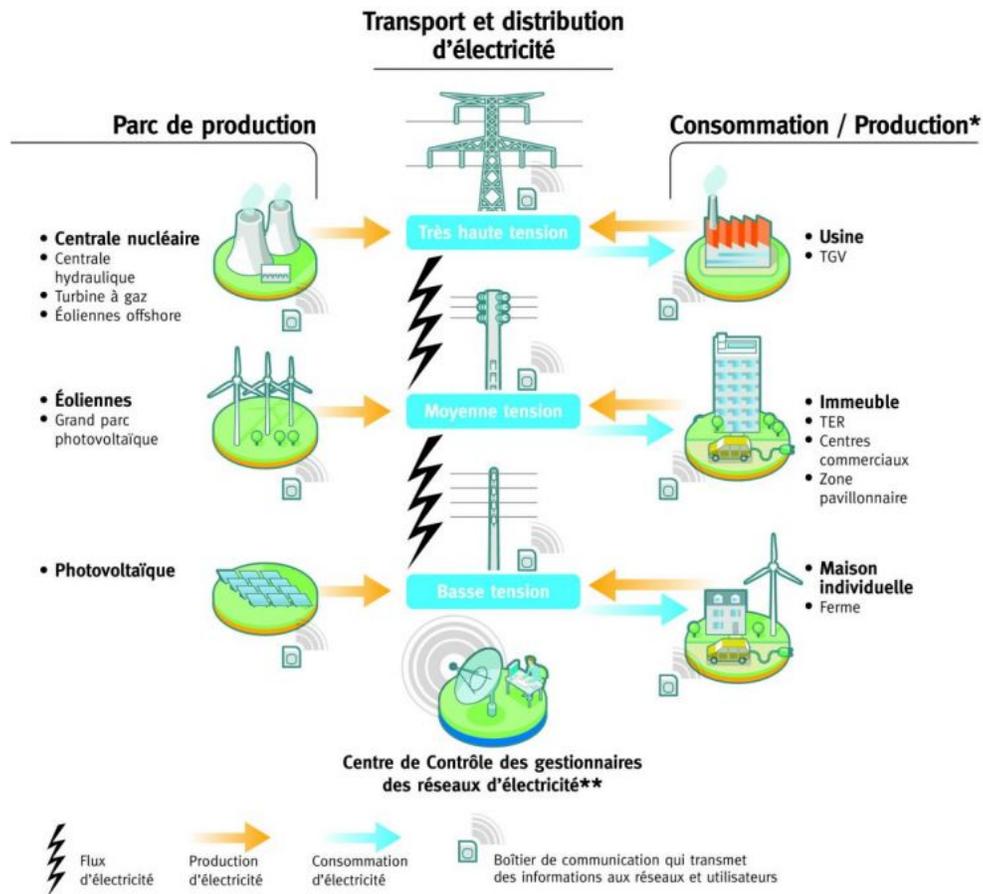


FIGURE 1.4 – Modèle général du Smart grid [20]

### 1.4.1 Technologies des smart grids

Le déploiement d'une architecture d'un réseau électrique intelligent repose sur la combinaison de couches d'infrastructure et de logiciels qui permettent la communication, la mesure, le contrôle et la surveillance [26].

Les technologies suivantes doivent être déployées pour répondre aux différentes exigences des Smart Grids :

#### 1.4.1.1 communication

Les technologies de communication intégrées permettent le contrôle en temps réel, la transmission de données et d'informations pour améliorer la fiabilité, la sécurité et l'utilisation des infrastructures tel que [26] :

##### **Home Area Network (HAN)**

Un réseau (HAN) recueille les données d'une série d'appareils dans la maison et les contrôle pour mieux gérer la consommation d'énergie. Pour optimiser la consommation d'électricité, les équipements domestiques intelligents (tels que les appareils de chauffage, les climatiseurs, les lave-linge, les sèche-linge, les réfrigérateurs, les cuisinières, les lave-vaisselle et les chargeurs de véhicules électriques) peuvent être surveillés et contrôlés par un centre de contrôle résidentiel ou par les consommateurs.

##### **Neighborhood Area Network (NAN)**

C'est un réseau de communication entre les compteurs intelligents et les concentrateurs du WAN. Il rassemble les données d'un grand nombre de résidences dans un quartier et les relie à un WAN. Les NAN sont fixés à l'extérieur des habitations ou sur les toits des bâtiments.

##### **Wide Area Network (WAN)**

Les données provenant de divers NAN sont combinées et envoyées aux utilitaires du réseau par le biais du WAN. Il permet également la communication longue distance entre les unités de production d'énergie, les réseaux de transmission et de distribution et centres de contrôle. L'utilitaire WAN est chargé de fournir les communications bidirectionnelles requises pour les sous-stations, la surveillance de la qualité de l'énergie et la réponse à la demande, ainsi que l'application de la gestion de la demande.

### 1.4.1.2 Interfaces évoluées et l'aide à la décision

Il s'agit de systèmes d'information qui donnent aux utilisateurs les outils dont ils ont besoin pour opérer de manière productive sur un réseau comportant un nombre croissant de variables, en réduisant la complexité du système. Les outils de visualisation synthétisent d'énormes volumes de données en représentations visuelles, facilement compréhensibles, les systèmes logiciels qui donnent diverses options lorsque des actions de l'opérateur système sont requises, et les simulateurs pour la formation opérationnelle et l'étude de cas [26].

### 1.4.1.3 Outil de mesure

#### PMU :

Unités de mesure des phaseurs (PMU ou synchrophaseurs) sont des appareils qui mesurent la phase et la fréquence d'une ou de plusieurs phases de tension. Les données de phaseurs sont utilisées pour la surveillance du réseau et le système de connaissance de la situation. Les données sont synchronisées en utilisant un GPS [27].

### 1.4.2 Compteurs intelligents (smart meters) :

Un compteur intelligent est un appareil qui combine des technologies avancées pour mesurer la consommation et la production d'énergie par les clients de manière fiable, efficace et en temps réel sur un réseau décentralisé. Il mémorise et restaure les informations sur l'énergie, la puissance, tension, tarif, etc [28].

### 1.4.3 Microgrid

Un microgrid est un petit réseau électrique intelligent qui s'appuie sur des méthodes locales de production d'électricité et de chaleur pour fournir de l'électricité à un petit nombre de consommateurs afin de leur fournir une alternative moins chère et plus fiable au réseau.

La particularité des microgrids par rapport aux smart grids ou tout autre type de réseau est que ces smart microgrids peuvent être synchronisés avec le réseau général ou fonctionner en mode îlot grâce à des solutions de stockage et des systèmes de contrôle intelligents [29].

#### 1.4.4 Résilience des smart grids

En général, la résilience est considérée en tant que capacité, pour un système donné, de surmonter les altérations provoquées par un ou des éléments perturbateurs, pour retrouver son fonctionnement normal. Un système résilient est un système sécurisé, fiable, auto-guérison et tolérant aux pannes.

En limitant la propagation des perturbations, un réseau électrique intelligent résilient doit pouvoir s'adapter aux menaces, aux défaillances matérielles et aux autres effets déstabilisant. Les réseaux intelligents résilients peuvent se reconfigurer pour tirer parti des interruptions.

La figure 1.5 représente les composants de la résilience du réseau électrique intelligent.



FIGURE 1.5 – Les composants de la résilience du réseau électrique intelligent [30]

#### 1.4.5 Défaillance en cascade dans les smart grid

L'un des grands problèmes dont souffre le smart grid est celui des défaillances en cascade. Le dysfonctionnement d'un nœud peut entraîner des défaillances séquentielles dans l'ensemble du système [31].

Différentes technologies et ressources sont intégrées dans un réseau électrique intelligent. Il existe deux réseaux, un réseau électrique et un réseau de communication/contrôle, qui sont fortement couplés. En d'autres termes, le réseau de communication fonctionne en fonction de l'électricité fournie par le réseau électrique. D'autre part, le réseau électrique doit être contrôlé par le réseau de communication/contrôle, ce qui rend ces deux réseaux interconnectés et mutuellement dépendants. Cependant, cette interdépendance croissante rend le réseau électrique intelligent plus fragile que le réseau électrique classique.

### 1.4.6 Délestage électrique

Le délestage est un moyen rentable et efficace d'éviter les ruptures de tension, ainsi qu'un moyen d'atténuer la surcharge des lignes lorsque le réseau est surchargé. Par conséquent, le délestage peut contribuer à éviter les pannes d'électricité [32].

En outre, le délestage permet au système perturbé de retrouver un nouveau point de fonctionnement stable. Le terme "délestage" désigne un ensemble de directives visant à réduire la demande sur les réseaux électriques. Il est fréquemment effectué pour sortir le système électrique d'un scénario d'urgence ou d'un état d'alerte [7].

## 1.5 Conclusion

Dans ce chapitre, nous avons tout d'abord défini les villes intelligentes, ainsi que les facteurs qui rendent une ville intelligente et ses composants, ensuite nous avons abordé le concept des réseaux électriques intelligents (smart grids), notamment ses technologies, l'outil de mesure, la notion des microgrids et la résilience, enfin nous avons clôturé par le délestage des smart grids.

Dans le deuxième chapitre, nous aborderons le système décisionnel.

# Chapitre 2

État de l'art : Systèmes décisionnels

## 2.1 Introduction

Les systèmes décisionnels ont une influence considérable sur la gestion de divers problèmes au niveau d'une entreprise ou une administration.

Les SIAD utilisent les techniques de data mining, ce dernier représente un outil très puissant et performant qui est utilisé dans l'aide à la décision dans le cas de problèmes liés à la résilience dans les smart grids, ainsi que les systèmes multi-agent qui constituent une technique fiable et efficace pour assurer la résilience des réseaux intelligents, et les méthodes de décision de groupe qui sont des méthodes puissantes qui génèrent un plus grand nombre de solutions alternatives de meilleure qualité.

Dans ce chapitre, nous présentons les notions relatives au système d'aide à la décision, le rôle des systèmes intelligents d'aide à la décision dans l'amélioration de la résilience dans les smart grids, et l'utilisation de différentes techniques de data mining comme l'apprentissage automatique, l'apprentissage profond, ainsi que les systèmes multi-agent qui répondent au concept d'intelligence du système à cause de l'autonomie d'agents, et les méthodes de décision de groupe dans la prévision des coupures imminente, dans le processus de rétablissement ou même dans l'anticipation des défaillances en cascade.

## 2.2 Aide à la décision

L'aide à la décision est l'activité de la personne, qui aide à obtenir des éléments de réponse aux questions posées par une partie prenante dans un processus de décision, grâce à l'utilisation de modèles explicites mais pas obligatoirement complètement formalisés. Ces éléments concourent à éclairer la décision, ou tout simplement favoriser un comportement qui améliore la cohérence entre le système de valeurs de cette partie prenante avec l'évolution du processus et les objectifs [33].

### 2.2.1 Décision

La décision est l'action prise par un décideur face à une difficulté, c'est-à-dire pour trouver une solution à un problème qui se pose à un individu ou à une organisation [11].

### 2.2.2 Processus d'aide à la décision

Un processus d'aide à la décision est un ensemble d'activités qui commence par un problème, et se termine par un ensemble d'alternatives qui peuvent fournir la solution dont le décideur a besoin [34].

**1- L'information** : C'est une étape d'identification du problème à résoudre, pour laquelle des informations pertinentes doivent être recherchées en fonction des préoccupations du décideur.

**2- La conception** : C'est la phase de modélisation proprement dite où le décideur génère les différentes alternatives qui rendent toutes les possibilités possibles. Cette étape conduit à différentes voies possibles pour résoudre le problème.

**3- Le choix** : C'est la phase de restriction de toutes les possibilités du sous-ensemble d'options sélectionnées.

**4- L'évaluation** : Cette étape permet d'évaluer la solution retenue (décision prise). Elle peut conduire à un retour à l'une des trois premières étapes, ou à l'inverse, à la validation de la solution.

La figure 2.1 représente le processus de décision.

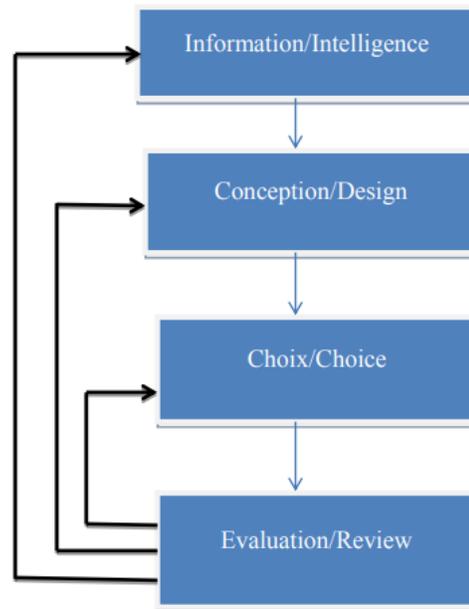


FIGURE 2.1 – Le processus de décision [34]

### 2.2.3 Les acteurs d'aide à la décision

Un participant à l'aide à la décision est tout intervenant impliqué dans le processus d'aide à la décision [35]. Il existe plusieurs acteurs que nous citons dans le tableau 2.1.

Acteur	Rôle
Le décideur	Évolue les objectifs. Impose ses préférences sur l'évolution du processus [33].
L'analyste	Construire un système de préférence. Définir des modèles d'aide à la décision pour en tirer parti pour obtenir des réponses.
Agis	Se soucient des conséquences d'une décision. Ils interviennent directement dans le processus.
Candidat	Demande à étudier et allouer des fonds.
Négociateur	Habilités par les décideurs à affirmer leurs positions, et à rechercher des compromis dans les négociations.
Médiateur	Aider les décideurs (ou négociateurs) à rechercher un compromis.

TABLE 2.1 – Le rôle de différents acteurs d'aide à la décision

### 2.2.4 Décision du groupe

Une décision de groupe est une décision qui concerne plusieurs personnes (décideurs) plutôt qu'une seule personne. Le groupe peut s'engager dans deux sortes d'activités avant de prendre une décision : la négociation et la participation. Par conséquent, il existe une décision basée sur la négociation et une autre basée sur la participation [11].

### 2.2.5 Topologies de la décision

Il existe deux types de décisions : décision programmable et non programmable. Le tableau 2.2 explique la différence entre ces deux décisions [36].

Décision programmable	Décision non programmable
Les impacts sont sous contrôle.	Décisions risquées et ont des conséquences importantes.
Les décideurs les connaissent bien.	Plus difficiles surtout en raison du manque de connaissances et d'expérience.

TABLE 2.2 – Comparaison entre les décisions programmables et non programmables

### 2.2.6 Aide à la décision multicritère

L'aide à la décision multicritères (Multi criteria decision aiding/analysis) est une analyse destinée à interpréter un ensemble cohérent de critères, permettant de comprendre les différentes conséquences des alternatives.

L'un des principaux objectifs de l'approche MCDA est d'aider les décideurs à organiser et à synthétiser ces informations afin qu'ils se sentent à l'aise et en confiance lors de la prise de décisions, ainsi minimiser le risque de regret après une décision en ayant la certitude que tous les critères ont été correctement pris en compte [37].

### 2.2.7 Typologie de problème traité par MCDA :

Les quatre principales problématiques traitées par MCDA sont : la problématique de choix, de tri ou de classement et la problématique de description [33].

Le tableau 2.3 représente les différentes problématiques traitées par MCDA.

Les problématiques	Traitement
Problématique de choix	Faire un choix parmi plusieurs alternatives.
Problématique de tri	Trier les actions dans des catégories préalablement définies. Les catégories peuvent être partiellement ou entièrement triées.
Problématique de classement	Ce problème nécessite l'utilisation complète de toutes les informations afin de comparer les actions.
Problématique de description	Décrire les actions et leurs conséquences d'une manière formalisée et systématique pour que les décideurs puissent évaluer ces actions

TABLE 2.3 – Les différentes problématiques traitées par MCDA

## 2.2.8 Les principales méthodes multicritères

L'aide à la décision multicritère est une branche majeure de la recherche opérationnelle qui regroupe plusieurs écoles de pensée, principalement américaine avec l'invention par Thomas Saaty de la méthode Analytic Hierarchy Process (AHP) et européenne avec l'invention par "Bernard Roy" des méthodes ELECTRE I, ELECTRE II, et ELECTRE III au laboratoire LAMSADE 6. Ces méthodes et calculs permettent de sélectionner la meilleure solution ou la solution idéale parmi un ensemble de solutions, ou d'enlever certaines des solutions globales [37].

### 2.2.8.1 PROMETHEE

La méthode PROMETHEE (Preference Ranking Organisation Methods for Enrichment Evaluation) a été proposée par Jean Pierre Brans en 1982. Il fait partie d'une famille de méthodes de surclassement de valeur [38]. Elles permettent de définir la relation d'indifférence, de surclassement et d'incomparabilité entre deux situations du meilleur au pire à travers un système de préférences floues [39].

### 2.2.8.2 ELECTRE

Les méthodes D'ELECTRE c'est une série de méthodes appelées méthodes de surclassement basées sur des comparaisons d'action deux à deux. Celles-ci nécessitent peu d'informations pour leur implémentation, et ces informations sont facilement accessibles aux décideurs, elles fournissent donc des résultats fiables [39].

La familles d'ELECTRE contient les méthodes suivantes : ELECTREI, ELECTREII, ELECTREIII, ELECTRE IV et ELECTRE tri.

### 2.2.8.3 Analytic Hierarchy Process

La méthode AHP (Analytic Hierarchy Process) a été développée par Saaty en 1980. La force de cette approche réside dans sa similitude avec

les mécanismes humains de prise de décision, à savoir la décomposition, le jugement et la synthèse. Sa particularité est sa capacité à gérer différentes catégories de critères, à savoir des critères qualitatifs et quantitatifs. Aujourd'hui, il est largement utilisé dans divers domaines, notamment l'économie, l'écologie, l'industrie, etc [40]

## 2.3 Systèmes d'aide à la décision (Decision Support System)

Le système d'aide à la décision est un système d'information informatisé qui facilite le processus de prise de décision d'une entreprise ou d'une organisation. Les SAD soutiennent la prise de décision aux niveaux de la gestion, de l'exploitation et de la planification d'une organisation. Les systèmes d'aide à la décision peuvent être totalement humains, automatisés ou combinaison des deux [41].

### 2.3.1 Les taxonomies des systèmes décisionnels

Les différentes taxonomies du système décisionnel sont représentés sur la figure 2.2 :

- **Un SAD actif** : de telles décisions ou idées peuvent être suscitées.
- **Un SAD passif** : c'est un système d'aide à la décision, bien qu'il ne soit pas possible de proposer des solutions spécifiques à la prise de décision.
- **Un SAD coopératif** : permet aux décideurs de compléter, d'améliorer ou de modifier les propositions de décision du système avant de les renvoyer au système pour validation. Le système affine et améliore les propositions du décideur et renvoyez-la-lui pour la validation. Le processus est ensuite répété jusqu'à ce qu'une solution consolidée soit obtenue [42].

### 2.3.2 Architectue des SAD

L'architecture d'un système d'aide à la décision est représenté dans la figure 2.2, composée de cinq parties distinctes : les utilisateurs, le système

de gestion de base de données (SGBD 7), le moteur d'inférence, le système de gestion de base modèles (SGBM 8), interface d'utilisateur [43].

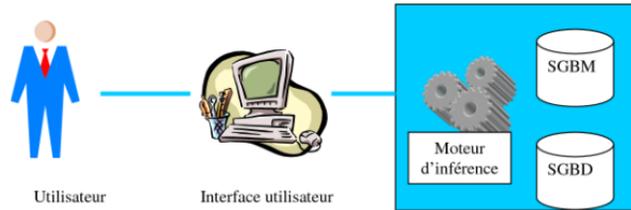


FIGURE 2.2 – Architecture d'un SAD [43]

### 2.3.3 Fonctionnalité des SAD

Les différentes fonctionnalités des SAD :

- Ils doivent aider à résoudre des problèmes lâches ou mal structurés en liant le jugement humain et les informations informatiques.
- Ils doivent avoir une interface simple et conviviale pour éviter que les utilisateurs ne se perdent face aux complexités du système.
- Ils doivent s'adapter au fil du temps et les décideurs doivent être capables de résister à des conditions qui évoluent rapidement et d'adapter le SAD aux nouvelles situations
- Ils ne peuvent pas avoir d'outils de type boîte noire. Le SAD doit fonctionner de manière comprise et acceptée par les décideurs.
- Ils doivent confier le contrôle de toutes les étapes du processus décisionnel au décideur afin que celui-ci puisse à tout moment contester les recommandations émises par le SAD [36].

## 2.4 Les systèmes intelligents d'aide à la décision (SIAD)

Un système intelligent d'aide à la décision (SIAD) ou IDSS en anglais est un système d'information intelligent qui diminue le temps de prise de décisions et optimise la cohérence et la qualité des décisions. L'utilisation d'outils et de modèles d'intelligence artificielle (IA) offre un accès

direct à l'expertise, et leur flexibilité leur permet de soutenir les processus d'apprentissage et de prise de décision. Leur intégration avec des modèles numériques et/ou statistiques dans un système donne une précision, une fiabilité et une utilité exceptionnelles. [11].

Un SIAD est la combinaison entre un DAS et l' intelligence artificielle.

### 2.4.1 Intelligence artificielle

L'intelligence artificielle est une discipline de l'informatique qui tente de construire des machines intelligentes opposées à l'intelligence naturelle de l'homme. Elle englobe actuellement toutes les théories visant à permettre à une machine d'imiter, voire de dépasser, les capacités cognitives des humains.

L'expression "intelligence artificielle" a été inventée en 1956, un an après le lancement d'une série de projets de recherche après la Seconde Guerre mondiale, et constitue l'une des disciplines d'étude les plus récentes dans le domaine des sciences et de l'ingénierie [44].

Un SIAD est la combinaison entre un DAS et une intelligence artificielle.

### 2.4.2 Science de données (Data science)

La science de données (connue aussi comme fouille de données ou data mining). Le data mining désigne un ensemble de méthodes et d'algorithmes dont le but est de découvrir et d'extraire de la connaissance ainsi que des modèles à partir de données quelconques en quantités importantes. Ces données sont issues de grandes bases de données et d'entrepôts de données [45].

Le data mining consiste à expliquer le passé et à prédire l'avenir grâce à l'analyse des données. La figure 2.3 représente la fusion de différents domaines (statistiques, apprentissage automatique, intelligence artificielle et technologie de base de données).

Le data mining joue un rôle important dans le fonctionnement des smart grids, et c'est aussi un outil très puissant en ingénierie et en médecine.

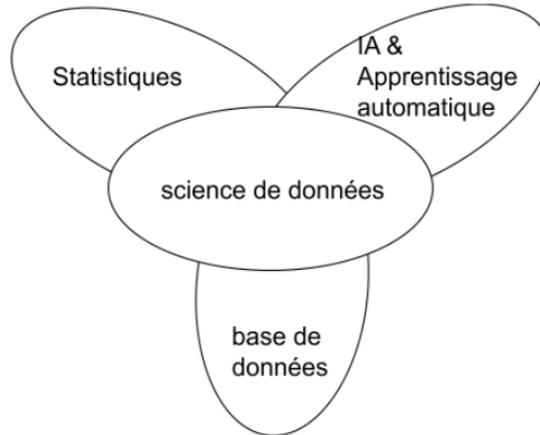


FIGURE 2.3 – Data science comme un domaine multidisciplinaire [46]

## 2.5 SIAD et résilience de smart grid

Les systèmes décisionnels intelligents sont utilisés pour améliorer la résilience dans les SG. SIAD aide les opérateurs des SG de prendre une décision en cas de coupure électrique soit lors du processus de prédiction ou dans le rétablissement, quelle que soit la cause de la panne (panne d'équipement, piratage, catastrophe météorologique, etc.). Différentes techniques sont utilisées pour améliorer la résilience dans les smart grids [11].

Les travaux connexes existants dans la littérature sont classés d'après les techniques utilisées dans cinq catégories principales : apprentissage automatique, apprentissage en profondeur, apprentissage par renforcement en profondeur, prise de décision en groupe et systèmes multi-agents.

### 2.5.1 L'apprentissage automatique

L'apprentissage automatique fait référence à la création, à l'analyse et à l'application de méthodes qui permettent à un ordinateur de s'évaluer lui-même et d'accomplir ainsi des tâches difficiles à réaliser à l'aide de méthodes algorithmiques classiques. Son objectif est d'extraire et d'exploiter

automatiquement les données [47].

La figure 2.4 représente la relation entre l'intelligence artificiel, l'apprentissage automatique et l'apprentissage profond, qui est une relation d'inclusion entre eux.

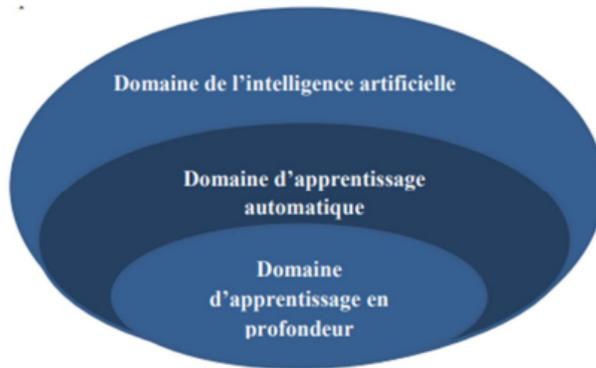


FIGURE 2.4 – La relation entre IA, ML, DL [48]

On peut distinguer trois catégories d'apprentissage automatique : les apprentissages non-supervisés, supervisés et apprentissage par renforcement.

#### 2.5.1.1 Support vector machine (SVM)

L'objectif de cette méthode est d'utiliser un séparateur linéaire (hyperplan) entre les points de données et maximiser la distance entre ces deux classes [49].

#### 2.5.1.2 Travaux connexes

Une technique d'apprentissage automatique est centrée sur la création d'algorithmes qui aident à la prédiction de tout type d'interruption de courant. SVM peut être utilisé pour anticiper les risques liés aux ouragans [50].

Un modèle pour un système d'alerte précoce de réseau intelligent est proposé. L'un des avantages du modèle est sa capacité à détecter la majorité

des défaillances en cascade à l'aide de SVM, ce qui permet de prévoir à temps les scénarios de panne [51].

### 2.5.1.3 Réseaux de neurones artificiels

Les réseaux neuronaux sont des modèles de traitement de l'information qui sont inspirés du fonctionnement des neurones biologiques du cerveau humain. Les réseaux de neurones sont constitués de neurones interconnectés organisés en couches et qui par la suite s'est rapproché des méthodes statistiques [52].

Les chercheurs incluent fréquemment les réseaux neuronaux comme éléments clés de leurs modèles. Ils les ont utilisés pour la récupération de l'énergie et la prévision des pannes, l'objectif principal étant d'accroître la résilience du réseau intelligent.

### 2.5.1.4 Travaux connexes

Un réseau neuronal qui a été proposé, fonctionne avec des équations de flux de courant alternatif. Cette stratégie permet de localiser les réseaux électriques en panne sur une ou deux lignes à l'aide des données reçues des PMU [53].

Une nouvelle application des réseaux neuronaux artificiels (ANN) a été mise en œuvre pour la prévention des pannes d'électricité dans les micro-grids sensibles aux situations anormales [54].

### 2.5.1.5 Approches bayésiennes

Les méthodes bayésiennes sont des méthodes basé sur le théorème de Bayes probabilité les réseaux bayésiens, l'inférence bayésienne, etc [55].

Ces méthodes ont surtout été employées pour prévoir les pannes électriques des réseaux.

### 2.5.1.6 Travaux connexes

Une méthodologie était développée basée sur les observations historiques du radar à haute résolution des tempêtes afin de générer des modèles de taux de défaillance en fonction de la météo. Un algorithme bayésien de prévision des pannes est utilisé pour tester les pannes d'électricité signalées [56].

### 2.5.1.7 Les arbres de décision

un outil d'aide à la décision qui permet de répartir une population d'individus en groupes homogènes en fonction d'un objectif fixés selon des attributs discriminants [57]

Les différents algorithmes d'arbres de décision : CART, OC1, C4.5, ID3, SPRINT, SLIQ, ect.

### 2.5.1.8 Travaux connexes

Pour estimer la taille des pannes d'électricité, un arbre de décision prédicteur en trois étapes a été proposé. Ainsi le délestage, le décalage et le relais de sous/sur-fréquence peuvent être modélisés pour simuler le processus d'événements en cascade [58].

## 2.5.2 L'apprentissage profond (Deep learning)

L'apprentissage approfondi est un sous-ensemble de l'apprentissage automatique. Quand on parle de l'apprentissage approfondi, on fait référence à des réseaux artificiels de neurones profonds [59].

Un schéma d'un apprentissage profond avec de nombreuses couches est présenté dans la figure 2.5 :

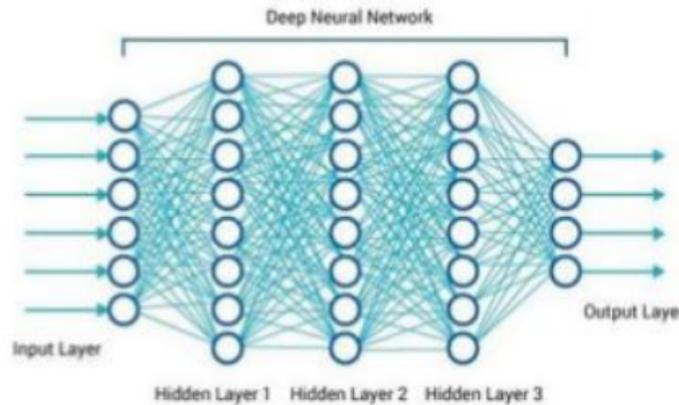


FIGURE 2.5 – Schéma illustratif de DL avec plusieurs couches

### 2.5.2.1 deep-belief networks (DBN)

Les réseaux de croyances profondes (DBN) sont considérés comme des modèles génératifs qui contiennent plusieurs couches de variables cachées. Ces modèles ont été appliqués avec succès dans de nombreux domaines. Les machines de Boltzmann restreintes (RBM) sont les composants constitutifs des réseaux de croyance profonds [60].

### 2.5.2.2 Travaux connexes

Le modèle deep-belief networks a été proposé dans le but d'améliorer la résilience des smart grids et mettre fin aux défaillances en cascade. Ce modèle est conçu pour prévoir des coupures imminentes de courant en cas d'aléas météorologiques à l'aide des données réelles historiques [61].

### 2.5.3 Systèmes multi agents

Un agent est une entité physique ou logicielle qui peut participer à des activités organisées et interagir avec d'autres agents et utilisateurs pour atteindre ses objectifs.

Un système multi-agents est un ensemble d'agents interagissant les uns avec les autres dans un environnement partagé, avec la possibilité de former

ou de rejoindre une organisation [62].

Les chercheurs ont utilisé les SMA pour résoudre les problèmes de la résilience. Lors des tests, ils ont démontré une efficacité exceptionnelle, notamment dans les micro-réseaux.

### 2.5.3.1 Travaux connexes

Les smart grid utilisent un système multi-agents (SMA) pour détecter les problèmes avant d'effectuer des opérations de commutation pour rétablir les charges hors service.

Pour prévenir les défaillances en cascade, un algorithme de système multi-agent dans un réseau électrique intelligent avec des fonctions de communication bidirectionnelle été utilisé [63].

## 2.5.4 Apprentissage par renforcement profond

L'apprentissage par renforcement permet de résoudre le problème difficile qui consiste à relier les actions immédiates au retour d'information différé qu'elles fournissent. Comme les humains, les systèmes d'apprentissage par renforcement doivent parfois attendre avant de voir les résultats de leurs choix. Ils fonctionnent dans un contexte de rétroaction différée, où il peut être difficile de déterminer quelle action conduit à quel résultat sur plusieurs périodes [64].

### 2.5.4.1 Travaux connexes

Dans un smart grid, l'apprentissage par renforcement (RL) est utilisé pour arrêter les défaillances en cascade. Pendant la phase d'apprentissage de l'état d'action, l'algorithme d'apprentissage Q-learning a été utilisé pour apprendre au système la meilleure approche de sélection d'action. En conséquence, le système formé diminue la congestion des lignes de transmission en temps réel en limitant la puissance de sortie des générateurs [65].

## 2.5.5 Prise de décision d'un groupe

Nous pouvons également inclure la prise de décision d'un groupe comme un moyen de renforcer la résilience. Le terme "groupe" fait référence non seulement à un groupe de personnes, mais aussi à un groupe d'agents ou de machines capables de réaliser cette activité dans différentes phases [11].

### 2.5.5.1 Travaux connexes

Une nouvelle méthode basée sur le concept de "jalons de rétablissement génériques (GRM)" est proposée. Une combinaison de GRMs concernant les conditions réelles du système synthétiserait une stratégie de récupération donnée, et l'outil d'aide à la décision devrait réduire le temps de récupération et améliorer la fiabilité du système [66].

## 2.6 Synthèse

L'objectif de cette synthèse est de consolider les problèmes de résilience abordés dans les travaux connexes, et d'examiner les avantages et inconvénients des différentes catégories de travaux afin de justifier les choix de méthodes utilisées.

Le tableau 2.4 résume les différentes techniques utilisées dans la prédiction des pannes imminentes, l'anticipation de la défaillance en cascade et le rétablissement de l'électricité après une coupure, à fin d'améliorer la résilience des smart grids.

P1 : la prédiction des pannes imminentes.

P2 : l'anticipation de la défaillance en cascade.

P3 : le rétablissement de l'électricité après une coupure.

Références	Famille	Techniques	P1	P2	P3
[50]	Data mining	SVM	Oui	Non	Non
[51]	Data mining	SVM	Oui	Oui	Non
[53]	Data mining	RNA	Non	Non	Oui
[54]	Data mining	RNA	Non	Oui	Non
[56]	Data mining	appr bayésienne	Oui	Non	Non
[58]	Data mining	ML/AD	Oui	Oui	Non
[61]	Data mining	DL/DBN	Oui	Non	Non
[63]	SMA	Microgrids	Non	Oui	Oui
[65]	DRL	Q-learning	Non	Oui	Non
[66]	PDG		Non	Non	Oui

TABLE 2.4 – Classement de travaux de recherches

### 2.6.1 Utilisation de méthodes d'aide à la décision multi critères

Les approches d'aide à la décision multicritères classique comme ELECTRE, AHP, et autres sont dépassées et ne peuvent pas être utilisées pour des problèmes à la fois compliqués et incluant des technologies émergentes (Les données collectées par des équipements PMU, des compteurs intelligents, etc. ), l'utilisation des méthodes MCDA peut présenter un certain nombre de limites. Afin d'enregistrer correctement les préférences du décideur, un grand nombre d'entrées est nécessaire à chaque phase de la méthode [67].

### 2.6.2 Utilisation de techniques de data mining

L'apprentissage automatique, l'apprentissage profond, l'apprentissage par renforcement et les méthodes bayésiennes sont une grande famille de techniques que l'on peut trouver dans le data mining. Comme le montrent les travaux connexes, le data mining est une technique très puissante et efficace qui peut être utilisée dans l'aide à la décision, et elle s'est avérée particulièrement utile pour relever les défis liés à la résilience, mais elle peut présenter certaines limites, par exemple, le raisonnement à base de cas (CBR) est sensible aux données incohérentes et nécessite plusieurs cas [67].

Selon les résultats, l'application d'approches de data mining pour améliorer la résilience a donné les meilleurs résultats en termes d'anticipation des pannes et de rétablissement des smart grids après une panne de courant.

### 2.6.3 Utilisation de SMA

L'utilisation des systèmes multi-agents démontre qu'ils constituent une technique fiable et efficace pour assurer la résilience des réseaux intelligents. En raison de l'autonomie des agents, ils répondent à l'idée d'intelligence du système, mais ils présentent également certaines limites. La charge élevée imposée par la communication entre agents est l'un des défauts fondamentaux des SMA, surtout lorsqu'il s'agit de traiter de grandes quantités de données [62].

### 2.6.4 Utilisation de méthodes de décision du groupe

Pour faire face aux difficultés liées à la résilience, des procédures de prise de décision en groupe sont appliquées. Bien que ces méthodes puissent générer un plus grand nombre de solutions alternatives de meilleure qualité (qu'une seule personne ou entité effectuant la tâche) et conduire à une meilleure compréhension collective de la voie à suivre, le processus de prise de décision peut être lourd et long en raison des phases dans les cas extrêmes, cela rend ces méthodes irréalisables (catastrophes naturelles, ect) [68].

## 2.7 Conclusion

Dans ce chapitre, nous avons abordé les bases théoriques de l'aide à la décision, ainsi que les systèmes d'aide à la décision et la résilience des smart grids, on peut conclure que le système intelligent d'aide à la décision joue un rôle important dans la prévision des pannes électrique, rétablir l'électricité et anticiper les défaillances en cascade à travers différentes techniques

utilisée (data mining, SMA...) afin d'améliorer la résilience des smart grids.

Dans le chapitre prochain notre contribution : "l'amélioration de la résilience dans les smart grids à l'aide d'un système décisionnel" sera présentée.

# Chapitre 3

Contribution : Système décisionnel pour  
l'amélioration de la résilience du réseau électrique  
intelligent

### 3.1 Introduction

L'une des exigences cruciales des smart grids est l'amélioration de la résilience des systèmes aux pannes de courant. Malgré les progrès des technologies utilisées dans les smart grids, la prévision des pannes de courant, la restauration du système d'alimentation et le renforcement de la résilience sont toujours considérées comme des problèmes sérieux à gérer.

Dans ce chapitre nous allons proposer une architecture d'un système décisionnel capable de prévoir les coupures électriques et améliorer la résilience des smart grids, ce qui aide les opérateurs à prendre les mesures nécessaires avant la production des coupures.

Le système utilise le modèle smoothed convolutional neural network (s-cnn) pour prédire les pannes électriques.

### 3.2 Architecture d'un système décisionnel pour l'amélioration de la résilience dans les smart grids :

La figure 3.1 représente l'architecture proposée du système d'aide à la décision avec ses principaux composants.

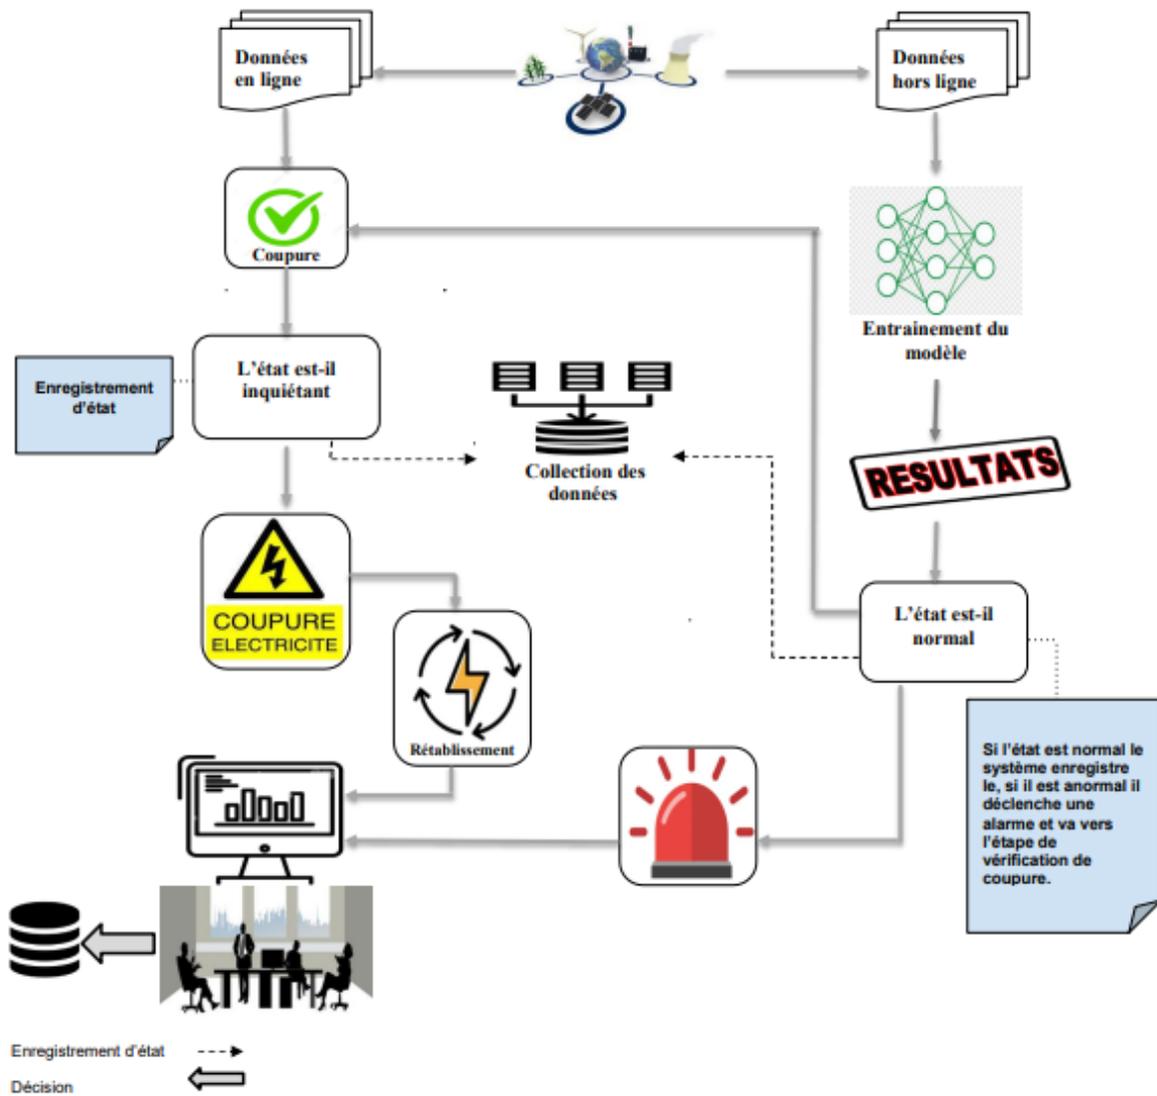


FIGURE 3.1 – Architecture proposée

### 3.2.1 Description de l'architecture :

L'architecture proposée aide les décideurs à suivre l'état du réseau, et à prendre une décision dans le cas d'un risque de coupure.

Premièrement le modèle S-CNN qui représente un modèle d'apprentissage profond sera entraîné en utilisant les données historiques des coupures, le résultat du modèle représente l'état initial du réseau (EIG), le système détermine l'état final (EFG) si le résultat est anormal (possibilité de coupure) le système déclenche une alarme qui apparaisse via une interface graphique, ce qui aide les opérateurs à empêcher la panne, sinon le système continue à fonctionner normalement et enregistre l'état dans la base de données historique avec les données nécessaires.

Après cette étape et en cas de possibilité de coupure le système vérifie l'état actuel (EAG), s'il est normal le système continue à fonctionner normalement sinon l'état actuel est inquiétant cela signifie une coupure. Le degré de danger sera déterminé à partir de seuils SED et SEE, Le système enregistre l'état actuel du réseau (normal, coupure) avec les données dans la base de données pour une future utilisation .

En cas de panne d'électricité, le système lance un plan de rétablissement de l'alimentation et affiche ce plan dans l'interface graphique pour que les décideurs puissent l'utiliser pour prendre la meilleure décision contre les coupures et puis la décision sera enregistrée dans une nouvelle base de données pour une future utilisation.

#### 3.2.1.1 Collections de données :

Des données réelles provenant de rapports des coupures historiques et de journaux de réparation viennent de diverses sources construits notre jeu de données. Ces données sont collectées et préparées par le biais d'un processus de collecte de données. Plusieurs types de données qui existent dans la base, telles que les interruptions non planifiées précédentes, deux classes ont été créées en fonction de l'état du réseau intelligent (normal, coupure).

### 3.2.1.2 le modèle Smoothed Convolutional Neural Network :

Les techniques d'apprentissage profond sont construites autour des réseaux neuronaux, qui sont un sous-ensemble de l'apprentissage automatique.

Les couches de nœuds sont constituées d'une couche d'entrée, d'un ou plusieurs niveaux cachés et d'une couche de sortie. Chaque nœud a un poids et un seuil auquel il est lié. Si la sortie d'un nœud dépasse un certain seuil, le nœud est activé et les données sont envoyées au niveau suivant du réseau.

Si ce n'est pas le cas, aucune donnée n'est envoyée au niveau suivant du réseau.

Les réseaux neuronaux se présentent sous différentes formes et tailles, et sont utilisés à des fins variées et pour différents types de données, les réseaux neuronaux récurrents, par exemple, sont fréquemment utilisés dans le traitement du langage naturel.

#### **Réseaux de neurones convolutifs (CNN) :**

Les réseaux neuronaux convolutifs (CNN) sont représentés dans la figure 3.2, qui sont une forme de réseau neuronal bien adaptée aux problèmes de vision par ordinateur tel que l'identification d'images, la reconnaissance de l'écriture manuscrite, ainsi que la reconnaissance faciale [69].

Leur structure est construite autour de l'échantillonnage d'une fenêtre ou d'une partie d'une image, de l'identification de ses caractéristiques, puis de l'utilisation des résultats pour produire une représentation. Ces modèles ont été les premiers modèles d'apprentissage profond puisqu'ils comportent de nombreuses couches.

En matière de taille des paramètres et de nombre de calculs, les réseaux de neurones convolutifs (CNN) sont notoirement difficiles.

Par conséquent, la mise en œuvre des réseaux de neurones convolutifs (CNN) nécessite une quantité importante de ressources de traitement et de stockage.[69]

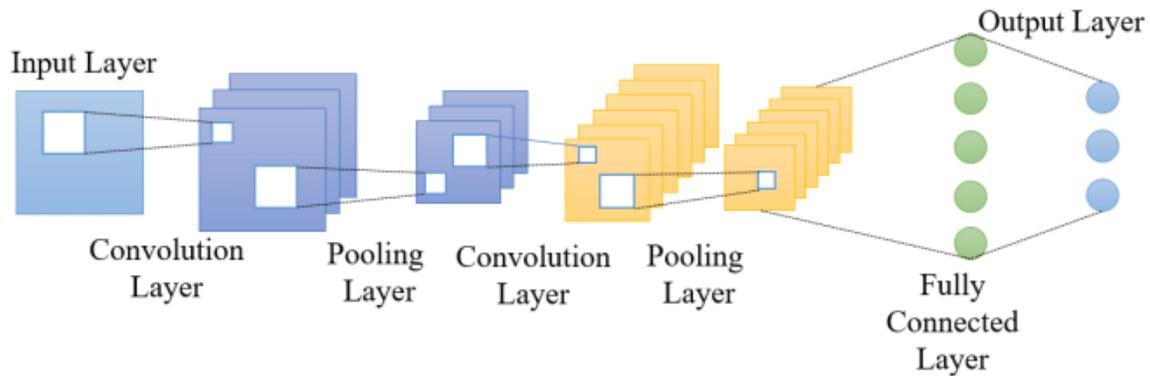


FIGURE 3.2 – Architecture d'un CNN [70]

Un réseau de neurone convolutif (CNN) est souvent constitué de plusieurs couches, notamment :

### 1) La couche de convolution :

La figure 3.3 représente les filtres et les cartes de caractéristiques qui forment la couche de convolution [71].

#### - Filtres :

Ce sont des matrices carrées de dimensions  $nK \times nK$ , où  $nK$  est un nombre entier qui est généralement un petit nombre comme 3 ou 5.

Ils constituent l'un des principaux composants des réseaux de neurones

convolutifs (CNN), et sont des neurones de la couche convolutive.

Les filtres sont également connus sous le nom de noyaux dans certaines situations.

Les noyaux sont une méthode utilisée dans le traitement traditionnel des images.

Dans une technique connue sous le nom de convolution, ils traversent les pixels de l'image d'entrée pour capturer un certain ensemble de caractéristiques.

Une carte de caractéristiques est un type de sortie d'un filtre.

La compréhension de la convolution est la première étape de la compréhension des réseaux de neurones convolutifs (CNN).

#### **- convolution :**

La convolution est le processus qui consiste à appliquer une fonction sur une matrice afin d'extraire des informations spécifiques.

Un filtre convolutif, souvent appelé noyau, est une fonction qui est mise en œuvre comme une fenêtre glissante sur une matrice. Dans la littérature, les deux noms sont utilisés de manière interchangeable.

#### **- Les cartes d'entités :**

Les cartes d'entités sont les sorties du filtre d'une couche convolutive, elles attirent l'attention sur des motifs spécifiques de l'image d'entrée, tels que les lignes horizontales, les bords des lignes verticales, etc.

Ces cartes de caractéristiques des différents neurones sont superposées pour former une couche de neurones convolutifs, ce qui permet à la couche d'apprendre des motifs et des propriétés complexes d'une image.

À mesure que nous progressons dans le réseau neuronal convolutif, les

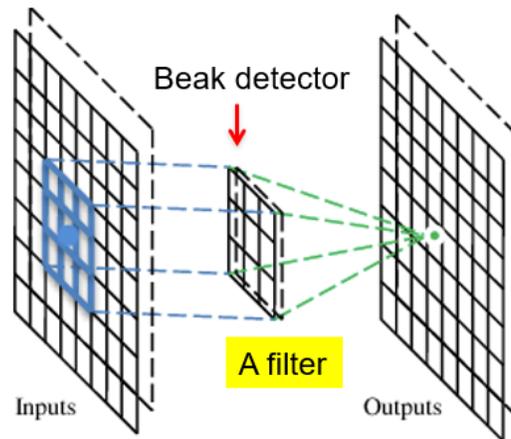


FIGURE 3.3 – Couche convolutive [72]

cartes de caractéristiques de la couche précédente deviennent les entrées d'une couche convolutive plus profonde.

## 2) Couche de mise en commun (pooling)

La deuxième opération essentielle dans les CNN est la couche de mise en commun. La convolution est bien plus difficile à appréhender que cette procédure. Une ou plusieurs couches convolutionnelles sont souvent suivies de couches de mise en commun.

Le but de cette couche est de diminuer ou de sous échantillonner la carte d'entités de la couche convolutionnelle. Les caractéristiques de l'image apprises dans les couches réseau précédentes sont résumées dans cette couche. Cela permet d'éviter que le réseau ne soit surchargé. De plus, la taille réduite de l'entrée réduit les dépenses de traitement et de mémoire, ce qui est bénéfique lors de la formation du réseau [73].

La couche de regroupement peut être considérée comme une fonction d'agrégation qui combine et extrait les aspects clés des informations ap-

prises par les couches précédentes.

Comme observé dans la couche convolutionnelle, elle n'effectue aucun traitement multiplicatif sur les cartes d'entrée. La couche de mise en commun effectue des tâches d'agrégation telles que max et average, comme il est présenté dans la figure 3.4. En pratique, la fonction d'agrégation la plus utilisée est max, connue sous le nom de "MaxPool".

Les couches sont filtrées à l'aide des méthodes d'agrégation de la couche de mise en commun.

La capacité de la couche de mise en commun à introduire l'invariance de localisation dans le réseau est son principal avantage.

Les entités peuvent être identifiées par le réseau indépendamment de l'endroit où elles se trouvent dans l'image, ce que l'on appelle l'invariance de l'emplacement.

La fonction d'agrégation de la couche de mise en commun est appliquée à tous les canaux d'entrée.

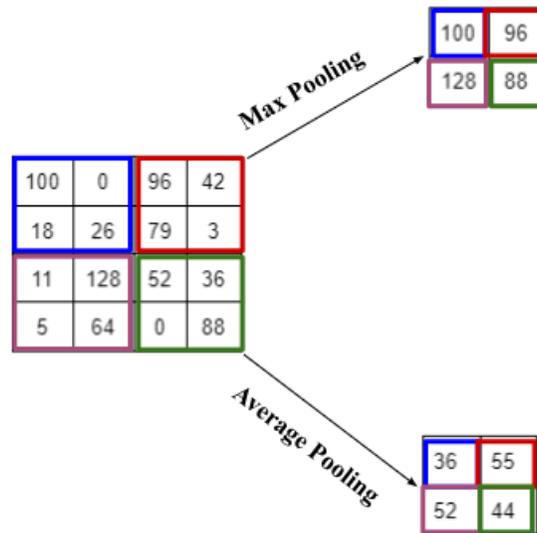


FIGURE 3.4 – Couche de mise en commun (pooling)

### 3) Blocs de construction d'un (CNN)

La couche du réseau entièrement connecté (Fully Connected Layer) (FC) présentée dans la figure 3.5 est un perceptron multicouche ou un réseau neuronal à feedforward régulier. La fonction d'activation de ces couches est souvent non linéaire. La couche fully connected est toujours la couche finale d'un réseau neuronal convolutif. Un softmax est utilisé pour sortir la probabilité qu'une entrée appartienne à une certaine classe dans ce scénario.

Pour produire les couches utilisées dans les réseaux de neurones convolutifs (CNN), la matrice d'image doit être aplatie par des processus de convolution et de mise en commun avant d'être transmise au (FC) [74].

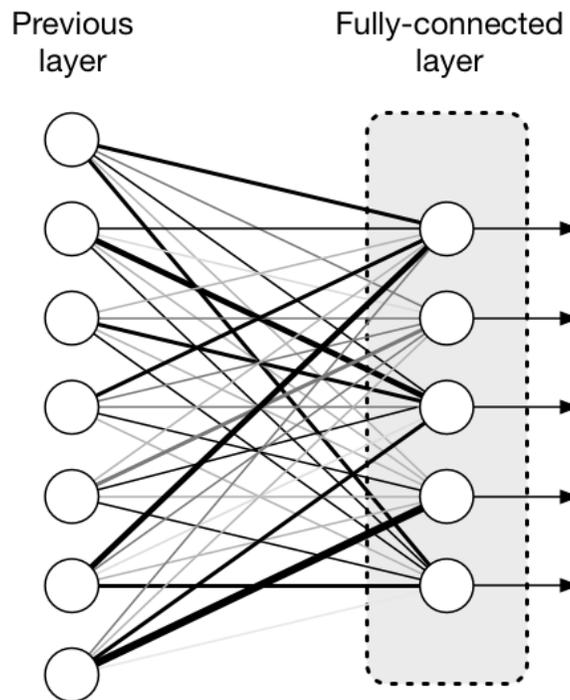


FIGURE 3.5 – Couche entièrement connectée [75]

## **Smoothed Convolutional Neural Network (S-CNN) :**

CNN est un modèle de traitement d'images qui est moins reconnu en tant qu'outil de prévision d'analyse de séries chronologiques qui dépend de la qualité des données d'entrée. Le lissage des données est l'une des stratégies permettant d'améliorer cette qualité.

Smoothed Convolutional Neural Network (S-CNN) est un nouveau modèle hybride de lissage exponentiel qui utilise le réseau de neurone convolutif (CNN) pour les problèmes de prévision de séries chronologiques.

Le CNN utilise les données brutes des pixels pour extraire les caractéristiques visuelles. Cependant, en raison du modèle numérique, l'extraction des données brutes n'est pas nécessaire dans l'analyse des séries chronologiques.

Smoothed-CNN (S-CNN) est une étude qui mélange un lissage exponentiel simple avec CNN pour réduire les erreurs de prévision. Elle encourage l'utilisation d'un nouvel optimum comme paramètre primaire dans le lissage exponentiel simple. Pour la ligne de base, nous utilisons (CNN), avec le nombre Lucas de couches cachées et choisissons l'approche optimale basée sur l'analyse des performances.

### **Pourquoi le S-CNN ?**

le réseau de neurone convolutif (CNN) offre des convolutions dilatées, dans lesquelles des filtres peuvent être utilisés pour calculer les dilatations de cellules, ce qui les rend appropriées pour la prévision des séries temporelles.

Le S-CNN est spécifiquement conçu pour la prévision des séries chronologiques, car le réseau neuronal peut mieux saisir les liens entre les dif-

férentes observations de la série temporelle, grâce à la taille des espaces entre chaque cellule.

### **Le lissage :**

Le lissage des données peut contribuer à améliorer la qualité des données, en réduisant les valeurs aberrantes des données de séries chronologiques.

Le lissage donne d'excellents résultats dans la prévision de petits ensembles de données, en faisant la moyenne de la valeur historique des données de séries temporelles, les processus de lissage améliorent les prédictions pour anticiper les valeurs futures, lisser la valeur des variations des données utilisées et éliminer le bruit, l'algorithme applique une valeur de pondération.

### **Type de lissage :**

Le lissage exponentiel simple (SES), lissage exponentiel (ES), la moyenne mobile (MA) et la marche aléatoire (RW) sont les quatre types de lissage de données les plus fréquents.

### **Lissage exponentiel avec optimum :**

Le résultat du lissage des données brutes ( $X_t$ ) est la donnée lissée ( $St$ ). Le facteur de lissage est un nombre qui spécifie le degré de lissage appliqué. La valeur se situe entre 0 et 1.

Comme l'effet de lissage est moindre lorsque la valeur est proche de 1, le processus d'apprentissage est rapide. En revanche, les valeurs plus proches de 0 ont un effet de lissage plus fort et sont moins sensibles aux changements récents (apprentissage lent) [76].

La prédiction : Pour déterminer l'état du réseau, notre prédiction se fera en 2 étapes à savoir :

### 3.2.1.3 Modèle de prévision

L'algorithme1 décrit la première étape de prédiction :

---

#### Algorithm1 : fonction prédiction

---

**BEGIN**

1 : Input new data()

2 : Training S-CNN model()

3 : EIG = getting output model

4 : FR=Facteur risque()

5 : **IF** (FR $\geq$ SED **AND** EIG=anormal) **THEN**

6 : EFG= Anormal

7 : Early Warning()

8 : allez vers vérification de coupure()

9 : **ELSE**

10 : EFG= normal

11 : **END IF**

**END**

---

Le résultat du modèle détermine l'état initial du réseau électrique (EIG) à partir du résultat et le facteur de risque (FR) qui sera calculer à partir de ces données, en utilisant la fonction "Facteur risque", l'état final du réseau (EFG) sera déterminé.

Si le facteur de risque (FR) est supérieur au (SED) et l'état initial (EIG) est anormal, l'état final du réseau (EFG) est anormal (il y a une possibilité de coupure), sinon l'état final (EFG) est normal.

Dans le cas d'état anormal le système déclenche une alarme pour avertir les opérateurs et aller vers l'étape de vérification de coupure. Cette fonction est utilisée pour calculer le facteur de risque.

## Facteur risque

$$FR = \frac{\sum_{i=1}^{NA} T[i] * PA}{NA} \quad (3.1)$$

**Le calcul de FR** : L'équation (3.1) calcule le facteur de risque (FR)

(FR) est calculé à partir des données en ligne, à travers la somme des attributs multiplier par (PA) le tout divisée par (NA).

La valeur du poids dépend de l'importance d'attribut dans l'influence sur la coupure.

Le (SED) et (SEE) sont des seuils calculés qui changent selon les données du dataset.

L'équation (3.2) calcule le seuil SED.

Le SED est calculer comme suit : le minimum de chaque colonne du data set qui a comme sortie coupure, multiplier par son poids, puis on fait la somme des minimum sur le nombre des attributs.

$$SED = \frac{\sum_{i=1}^{NA} \min T[j] * PA}{NA} \quad (3.2)$$

L'équation (3.3) calcule le seuil SEE.

Le SEE est calculer comme suit : le maximum de chaque colonne du data set qui a comme sortie coupure, multiplier par son poids, puis on fait la

somme des maximum sur le nombre des attributs.

$$SEE = \frac{\sum_{i=1}^{NA} maxT[j] * PA}{NA} \quad (3.3)$$

---

NA Nombre attribut

EAG Etat actuel grid

PA Poids attribut

SED Seuil état dangereux

SEE Seuil état extrêmement dangereux

EFG Etat final grid

EIG Etat initial grid

---

#### 3.2.1.4 vérification de la coupure :

La figure 3.6 représente la 2 ème étape de prédiction :

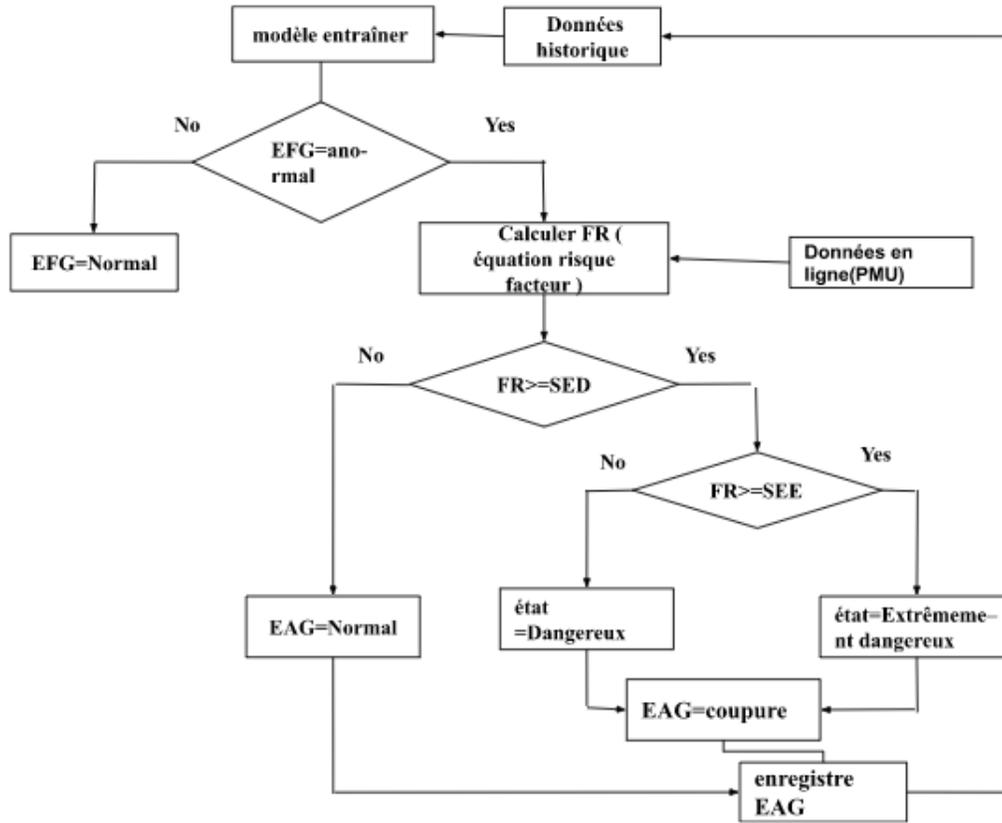


FIGURE 3.6 – Vérification de coupure

Dans cette étape le système vérifie le (EAG).

Le (FR) sera recalculer avec les données en ligne reçues, et sera comparer avec le seuil (SED) pour déterminer le (EAG), s'il est inférieur au seuil, le (EAG) est normal, l'état sera enregistrer dans la base de données et le système continue a fonctionner normalement, sinon l'état est inquiétant (coupure), pour déterminer le degré de danger, le (FR) sera comparer avec (SEE) s'il est inférieur au seuil, l'état est dangereux, sinon il est en état extrêmement dangereux, (EAG) sera enregistrer dans la base de données comme étant coupure.

### **3.3 Conclusion :**

Dans ce chapitre, nous avons présenté notre contribution « l'amélioration de la résilience des Smart Grids » à travers une architecture basé sur le modèle (S-CNN) du deep learning entraîné sur un jeu de données des coupures historiques, dans le but de prévoir les coupures électriques et définir le degré de danger pour améliorer la résilience des Smart Grids.

Dans le chapitre suivant, nous allons entamer les résultats et l'évaluation après avoir implémenté le modèle proposé.

# Chapitre 4

## Évaluation expérimentale des propositions

## 4.1 Introduction

Après avoir conclu la proposition de notre système d'aide à la décision, il est temps d'implémenter le modèle d'apprentissage profond proposé, dédié à la prédiction des coupures électriques, et nous devons passer à la phase d'évaluation des résultats à l'aide des outils et des métriques.

Ce chapitre commence par une description des ressources matérielles et logicielles utilisées, suivie d'une description des résultats obtenus des tests, et enfin, de l'interprétation de ces résultats.

## 4.2 les outils et bibliothèques utilisés

### 4.2.1 outils logiciels

#### 4.2.1.1 Python

Python est le langage de programmation open source le plus utilisé par les programmeurs. Ce langage de programmation a été propulsé au premier plan de la gestion des infrastructures, de l'analyse des données et du développement de logiciels.

En effet, l'un des avantages de Python est qu'il permet aux développeurs de se concentrer sur ce qu'ils font plutôt que sur la manière dont ils le font. Il a libéré les développeurs des contraintes de formes qui occupaient leur temps avec les langages plus anciens. Par conséquent, l'écriture de code en Python est plus rapide que dans d'autres langages [77].



FIGURE 4.1 – Logo de Python

#### 4.2.1.2 Tensorflow

Google a publié Tensorflow, un cadre de programmation pour le calcul numérique, en open source en novembre 2015. Tensorflow a rapidement gagné en popularité depuis sa création, devenant rapidement l'un des framework les plus populaires pour le Deep Learning et par conséquent les réseaux de neurones.

Son nom provient du fait que la plupart des opérations contemporaines des réseaux neuronaux sont effectuées à l'aide de tableaux de données multidimensionnels appelés tenseurs. L'équivalent d'une matrice est un tenseur.

Tensorflow est aujourd'hui utilisé dans les principaux produits de Google : Google Photos, Gmail et la reconnaissance vocale [78].



FIGURE 4.2 – Logo de TensorFlow

#### 4.2.1.3 NumPy

Le terme NumPy est en fait l'abréviation de " Numerical Python ". Il s'agit d'une bibliothèque Open Source en langage Python. On utilise cet outil pour la programmation scientifique en Python, et notamment pour la programmation en Data Science, pour l'ingénierie, les mathématiques ou la science, elle permet d'effectuer des calculs numériques avec Python. Elle introduit une gestion facilitée des tableaux de nombres [79].



FIGURE 4.3 – Logo de NumPy

#### 4.2.1.4 Pandas

La bibliothèque logicielle open-source Pandas est spécifiquement conçue pour la manipulation et l'analyse de données en langage Python. Elle est à la fois performante, flexible et simple d'utilisation. Grâce à Pandas, le langage Python permet enfin de charger, d'aligner, de manipuler ou encore de fusionner des données [80].



FIGURE 4.4 – Logo de Pandas

#### 4.2.1.5 Matplotlib

La bibliothèque Matplotlib de Python fournit un outil complet pour créer des visualisations statiques, animées et interactives. Matplotlib rend les choses difficiles possibles et les choses simples faciles [81].



FIGURE 4.5 – Logo de Matplotlib

#### 4.2.1.6 Scikit-learn

Scikit-learn, encore appelé sklearn, bibliothèque qui fournit une sélection d'outils efficaces pour l'apprentissage automatique et la modélisation statistique, notamment la classification, la régression et le clustering via une interface cohérente en Python. Cette bibliothèque, qui est écrite en Python, s'appuie sur NumPy et Matplotlib [82].



FIGURE 4.6 – Logo de Scikit-learn

#### 4.2.1.7 Keras

Keras est un réseau neuronal de haut niveau basé sur Python qui peut être utilisé avec Tensorflow ou Theano. Selon Chollet, Keras a été créé comme une interface plutôt que comme un système d'apprentissage end to end. Il fournit une collection d'abstractions de plus haut niveau et plus compréhensibles pour configurer les réseaux neuronaux indépendamment de la bibliothèque informatique backend [83].



FIGURE 4.7 – Logo de Keras

#### 4.2.1.8 Colab Pro

Google Colab Pro ou Colaboratory est un service gratuit de Google basé sur Jupyter Notebook et conçu pour la formation et la recherche en apprentissage automatique.

Cette plateforme permet de former des modèles d'apprentissage automatique sur le cloud. Nous n'avons pas besoin d'installer des logiciels ou quoi que ce soit sur notre ordinateur, à l'exception d'un navigateur [84].



FIGURE 4.8 – Google colab

## 4.2.2 outils matériels

Dans ce projet Colab Pro est utilisé pour entraîner le modèle proposé, et qui contient des (GPU) et (TPU) plus rapide nous permet d'attendre moins longtemps lors de l'exécution du code, et un processeur Intel (R) Core (TM) i5-3230M à 2,60 GHz.

## 4.3 Expérimentations

### 4.3.1 Dataset

Dans nos expérimentations, des données réelles provenant des rapports de pannes et des journaux de réparation de Seattle City Light sont utilisés. Cet ensemble de données contient de véritables données historiques sur les pannes qui ont été collectées et compilées au préalable.

Plus de 42 000 composants de données (interruptions non planifiées) sont répartis dans deux classes de sorties et 27 entités de cette collection (paramètres).

L'ensemble des caractéristiques comprend des nombres réels, des nombres entiers et des valeurs binaires, ces caractéristiques constituent les entrées du modèle.

Pour utiliser les algorithmes du Deep Learning, nous avons divisé le dataset en 2 ensembles comme le tableau 4.1 montre :

Ensemble	Dataset(42403)
Train_set (70%)	29682
Test_set (30%)	12721

TABLE 4.1 – Répartition du Dataset.

#### 4.3.1.1 La validation croisée (cross-validation) :

La validation croisée est une technique de ré-échantillonnage permettant d'évaluer les modèles d'apprentissage profond sur un petit échantillon de données.

Le processus ne comprend qu'un seul paramètre  $k$ , qui spécifie le nombre de groupes dans lesquels un échantillon de données doit être divisé. Par conséquent, le processus est fréquemment appelé  $k$ -fold cross-validation.

## 4.4 Mesure de performance des modèles :

### 4.4.1 Justesse (Accuracy) :

La mesure de performance intuitive la plus simple mentionné dans l'équation 4.1, qui est simplement le rapport entre les observations correctement prédites et toutes les observations.

$$Accuracy = \frac{VP + VN}{VP + FP + FN + VN} \quad (4.1)$$

### 4.4.2 Précision :

La précision est calculée comme suit (équation 4.2) pour répondre à la question "Quel est le pourcentage d'identifications positives réellement

correctes?".

$$Precision = VP/VP + FP \quad (4.2)$$

#### 4.4.3 Rappel (Recall) :

Le rappel fournit une réponse à la question "Combien de vrais positifs ont été identifiés avec succès?". C'est calculé d'après l'équation 4.3 suivante :

$$Recall = VP/VP + FN \quad (4.3)$$

#### 4.4.4 F1 Score :

C'est la moyenne de la précision et du rappel (équation 4.4)

$$F1Score = 2 * (precision * recall)/(precision + recall) \quad (4.4)$$

### 4.5 Algorithmes et résultats :

Pour valider notre choix du modèle pour prévoir les coupures électriques, une variété d'algorithmes d'apprentissage profond sont essayés, y compris CNN, LSTM, MLP et autres. Les modèles ayant sont entraînés en utilisant le même ensemble de données.

#### 4.5.1 k plus proches voisins (KNN) :

L'algorithme des k plus proches voisins est un classificateur d'apprentissage supervisé non paramétrique, qui utilise la proximité pour prédire comment un point de données individuel devrait être regroupé.

En résumé, l'objectif de l'algorithme KNN est de trouver les plus proches voisins du point de requête afin de pouvoir lui appliquer une étiquette de classe (normal, coupure).

Il est appliqué avec les paramètres présenter dans le tableau 4.2 suivant :

paramètre	Valeur
train_size	60%
test_size	40%
random_state	101

TABLE 4.2 – Paramètres utilisés pour KNN

les résultats étaient les suivants :

KNN	Précision	Rappel	F1-score	Support
coupure	0.86	0.68	0.76	2241
normal	0.95	0.98	0.97	14721
		Accuracy	0.94	16962

TABLE 4.3 – Résultat obtenue avec KNN.

Le tableau 4.3 montre la performance de l’algorithme des K plus proches voisins. En apprentissage automatique, un rapport de classification est une statistique d’évaluation des performances. Il est utilisé pour démontrer le support, le rappel, le F1 score et la précision du modèle KNN.

#### 4.5.2 Support Vector Machine (SVM) :

SVM est un algorithme d’apprentissage automatique supervisée utilisée pour résoudre les problèmes de classification. Chaque élément de données est représenté comme un point dans un espace de n dimensions, la valeur de chaque caractéristique étant la valeur d’une certaine coordonnée. Nous réalisons ensuite la classification en localisant l’hyperplan qui distingue clairement les deux classes (normal, coupure).

Il est appliqué avec les paramètres présenter dans le tableau 4.4 suivant :

les résultats étaient les suivants :

paramètre	Valeur
train_size	60%
test_size	40%
random_state	1

TABLE 4.4 – Paramètres utilisés pour SVM

SVM	Précision	Rappel	F1-score	Support
Blackout	0.96	0.68	0.98	14744
normal	0.98	0.70	0.82	2218
		Accuracy	0.95	16962

TABLE 4.5 – Résultat obtenue avec SVM.

Le tableau 4.5 montre la performance de l’algorithme Machine à vecteurs de support. En apprentissage automatique, un rapport de classification est une statistique d’évaluation des performances. Il est utilisé pour démontrer le support, le rappel, le F1 score et la précision du modèle SVM.

### 4.5.3 CNN :

Le modèle CNN classique été évaluer en utilisant les paramètres présentés dans le tableau 4.6 suivant :

paramètre	Valeur
num_epochs	10
filters	64
kernel_size	2
pool_size	2
random_state	2
loss	mse
optimizer	adam
activation	relu
verbose	2

TABLE 4.6 – Paramètres utilisés pour CNN

les résultats obtenus avec le modèle CNN sont présentés dans dans le tableau 4.7 suivants :

CNN	Précision	Rappel	F1-score	Accuracy
	0.83	0.70	0.79	0.96

TABLE 4.7 – résultat obtenue avec CNN.

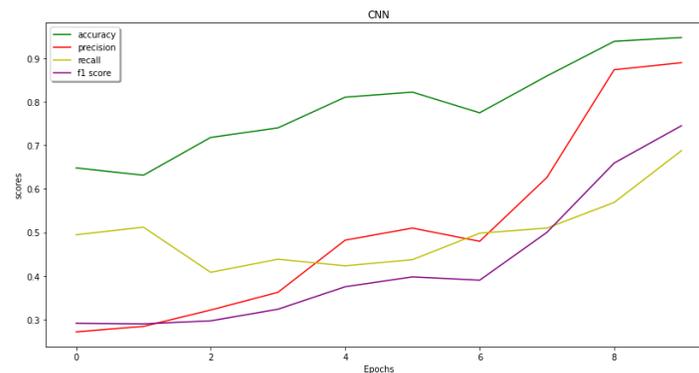


FIGURE 4.9 – Courbe CNN

D'après la courbe présentée dans la figure 4.9, qui représente la variation des mesures de performance du modèle CNN, on remarque que la précision et la justesse (accuracy) de l'apprentissage augmentent avec le nombre d'époque jusqu'à ce qu'il se stabilise à l'époque 8, ce qui reflète qu'à chaque époque le modèle apprend de plus en plus.

La même chose pour le F1 score et le rappel, elles augmentent avec le nombre d'époque.

#### 4.5.4 LSTM :

LSTM est un type spécial de (RNN), capable d'apprendre les dépendances à long terme, capable de mémoriser une information pendant une longue période, c'est leur comportement par défaut. Il est appliqué avec les paramètres présentés dans le tableau 4.8 suivant :

paramètre	Valeur
num_epochs	10
random_state	0
loss	mse
optimizer	adam
activation	relu
verbose	2

TABLE 4.8 – Paramètres utilisés pour LSTM

Les mesures de performance du modèle LSTM sont présentées dans le tableau 4.9 suivant :

LSTM	Précision	Rappel	F1-score	Accuracy
	0.85	0.58	0.67	0.94

TABLE 4.9 – Résultat obtenu avec LSTM.

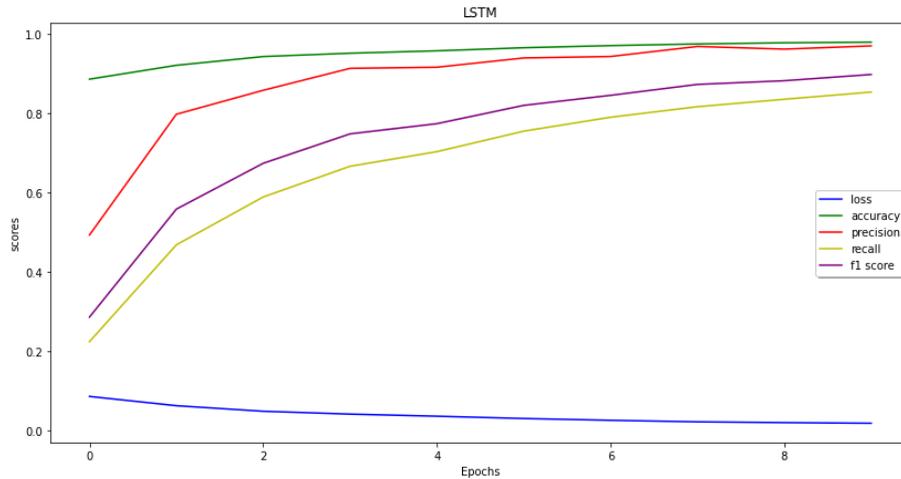


FIGURE 4.10 – Courbe LSTM

D'après la courbe présentée dans la figure 4.10, qui représente la variation des mesures de performance du modèle LSTM, on remarque que la précision, la justesse (accuracy), le rappel et F1 score de l'apprentissage augmentent avec le nombre d'époche, ce qui reflète qu'à chaque époque le modèle apprend de plus en plus.

La même chose pour l'erreur (loss), elle diminue avec le nombre d'époche.

#### 4.5.5 CNN-LSTM :

L'avantage de ce modèle est qu'il peut traiter de très longues séquences d'entrée, que le modèle (CNN) peut lire comme des blocs ou des sous-séquences, puis reconstituer par le modèle (LSTM).

Il est appliqué avec les paramètres présentés dans le tableau 4.10 suivant :

paramètre	Valeur
num_epochs	5
filters	64
kernel_size	1
pool_size	2
random_state	2
loss	mse
optimizer	adam
activation	relu
verbose	2

TABLE 4.10 – Paramètres utilisés pour CNN-LSTM

les résultats sont présentés dans le tableau 4.11 suivant :

CNN-LSTM	Précision	Rappel	F1-score	Accuracy
	0.96	0.68	0.76	0.97

TABLE 4.11 – Résultat obtenue avec CNN-LSTM.

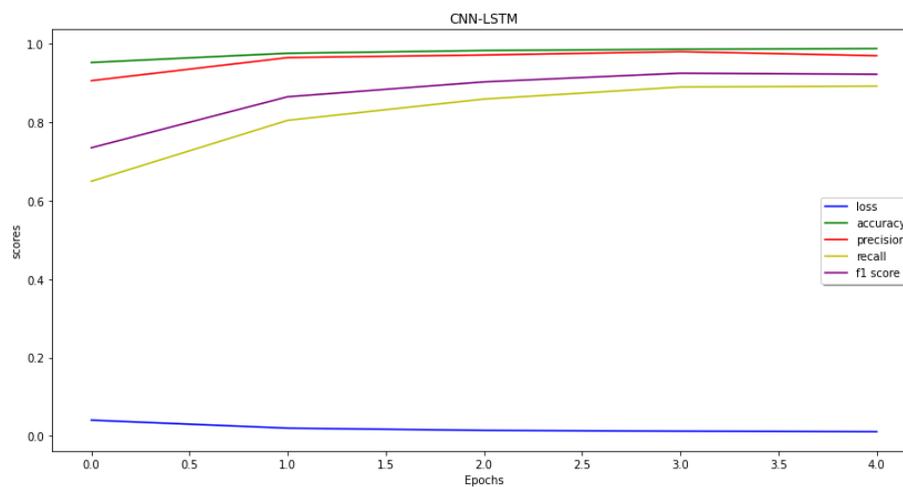


FIGURE 4.11 – Courbe CNN-LSTM

D'après la courbe présentée dans la figure 4.11, qui représente la variation des mesures de performance du modèle CNN-LSTM, on remarque que la précision, la justesse (accuracy), le rappel et F1 score de l'apprentissage augmentent avec le nombre d'époque, ce qui reflète qu'à chaque époque le modèle apprend de plus en plus.

La même chose pour l'erreur (loss), elle diminue avec le nombre d'époque.

#### 4.5.6 MLP :

Le perceptron multicouche (MLP) est une augmentation de réseau neuronal à action directe. Il comporte trois couches : une couche d'entrée, une couche de sortie et une couche cachée. Les données d'entrée ont été reçues par la couche d'entrée, la couche de sortie exécute la tâche souhaitée qui est la prédiction des coupures électriques, la couche cachée se trouve entre les couches d'entrée et de sortie.

Il est appliqué avec les paramètres présentés dans le tableau 4.12 suivant :

paramètre	Valeur
batch_size	100
num_epochs	10
kernel_size	2
loss	binary_crossentropy
optimizer	adam
activation	sigmoid, relu
kernel_initializer	uniform
input_dim	26

TABLE 4.12 – Paramètres utilisés pour MLP

les résultats du modèle MLP sont présentés dans le tableau 4.13 suivant :

MLP	Précision	Rappel	F1-score	Accuracy
	0.86	0.68	0.76	0.95

TABLE 4.13 – résultat obtenu avec MLP.

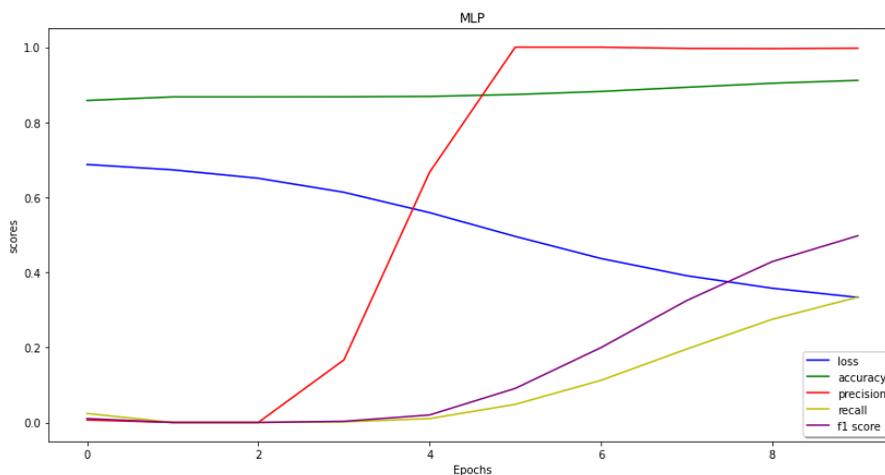


FIGURE 4.12 – Courbe MLP

D'après la courbe présentée dans la figure 4.12, qui représente la variation des mesures de performance du modèle MLP, on remarque que la justesse (accuracy), le rappel et F1 score de l'apprentissage augmentent avec le nombre d'époque, et la précision augmente aussi avec le nombre d'époque jusqu'à ce qu'elle se stabilise à l'époque 5, ce qui reflète qu'à chaque époque le modèle apprend de plus en plus.

La même chose pour l'erreur (loss), elle diminue avec le nombre d'époque.

#### 4.5.7 S-CNN :

Dans le but de limiter le problème de sur-apprentissage, un nombre des epochs précis a été utilisé qui est 50.

les résultats obtenus avec le modèle S-CNN sont présentés dans le tableau 4.14 :

S-CNN	Précision	Rappel	F1-score	Accuracy
	0.9875	0.68	0.76	0.9799

TABLE 4.14 – Résultat obtenue avec S-CNN.

paramètre	Valeur	signification
batch_size	64	définit le nombre d'échantillons qui vont être propagés à travers le réseau.
dropout_rate	0.5	C'est une technique de régularisation (pour combattre l'overfitting).
num_epochs	50	c'est le nombre maximum d'entraînement
filters	32	capturer l'ensemble de caractéristiques
kernel_size	2	fournit la longueur de la fenêtre de convolution 1D
pool_size	2	diminuer la taille de chaque carte de caractéristiques par un facteur de deux
random_state	2	le processus de brassage est sous contrôle
loss	binary crossentropy	compare chaque probabilité projetée à la classe réelle.
optimizer	adam	mettre à jour les pondérations itératives du réseau en fonction des données d'apprentissage
kernel regularizer	l2(0.001)	Regularizer pour imposer une pénalité sur le noyau de la couche
activation	sigmoid, relu	convertir l'entrée pondérée additionnée du noeud en une sortie

TABLE 4.15 – Paramètres utilisé et leurs signification

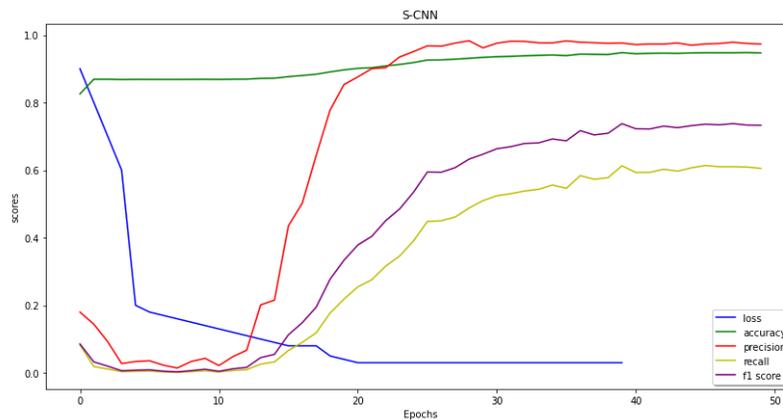


FIGURE 4.13 – Courbe S-CNN

D'après la courbe présentée dans la figure 4.13, qui représente la variation des mesures de performance du modèle S-CNN, on remarque que la justesse (accuracy) augmente avec le nombre d'époches, et aussi la précision, le rappel et F1 score de l'apprentissage augmentent avec le nombre d'époches,

jusqu'à ce stabilisé a l'époque 25, ce qui reflète qu'à chaque époque le modèle apprend de plus en plus.

La même chose pour l'erreur (loss), elle diminue avec le nombre d'époque.

## 4.6 Explication des méthodes utilisées :

Le tableau 4.15 représente les paramètres utilisés pour évaluer le modèle S-CNN et voici leurs explications :

### 4.6.1 Optimisateur "Adam" :

La stratégie d'optimisation peut faire toute la différence en termes d'obtention de résultats décents en quelques minutes, heures ou jours.

Adam est un algorithme populaire dans le domaine de l'apprentissage en profondeur car il obtient rapidement de bons résultats.

### 4.6.2 Fonction d'activation :

la fonction d'activation est une fonction mathématique appliquée à un signal en sortie d'un neurone artificiel, elle est souvent non-linéaire.

Sans une fonction d'activation, un réseau de neurones est juste un modèle de régression linéaire.

Il existe plusieurs types de c'est fonction, parmi lesquelles nous utilisons :

#### 4.6.2.1 Fonction Sigmoidale :

elle est particulièrement utilisée pour les modèles dont la sortie est une prédiction de probabilité. Sa sortie est entre 0 et 1, et elle a une courbe de forme S.

#### 4.6.2.2 Fonction ReLu :

c'est une fonction simple qui rend le  $X$  comme sortie s'il est supérieur a 0, sinon sa sortie sera un 0, sa fonction est :

$$Fonction(X) = \max(0, X) \quad (4.5)$$

#### 4.6.3 La Régularisation :

La régularisation est faite pour arrêter le problème de sur-apprentissage. En d'autre terme la complexité du modèle augmente de telle sorte que l'erreur d'apprentissage diminue mais pas l'erreur de test. Il existe plusieurs méthodes de régler ce problème, parmi ces méthodes on a :

##### 4.6.3.1 Le Dropout :

Il est généralement utilisé à la sortie de certaines des couches du réseau. Il enlève aléatoirement certains des neurones ainsi que leurs connexions d'entrée et de sortie pour éviter le overfitting.

##### 4.6.4 Epoch :

Lorsqu'un ensemble de données entier n'est transporté qu'une seule fois vers l'avant et vers l'arrière à travers le réseau neuronal, on l'appelle « EPOCH ».

##### 4.6.5 Batch Size :

Dans un lot unique, le nombre total d'instances de formation est présent. Il n'est pas possible d'alimenter le réseau neuronal avec l'ensemble complet de données en une seule fois.

Par conséquent, l'ensemble de données est divisé en un certain nombre de lots.

## 4.7 Prédiction et évaluation des modèles :

Paramètre	Valeur
Nombre total d'échantillons	42406
Nombre d'échantillons d'entraînement	29682
Temps de training (S)	153.171

TABLE 4.16 – Résumé de l'expérimentation

### 4.7.1 la courbe ROC :

Une courbe ROC (receiver operating characteristic) présentée dans la figure 4.14, est utilisée pour afficher les deux mesures d'un modèle de régression logistique suivantes :

- Sensibilité : Le taux d'individus positifs correctement prédits par le modèle.
- Spécificité : Le taux d'individus négatifs correctement prédits par le modèle.

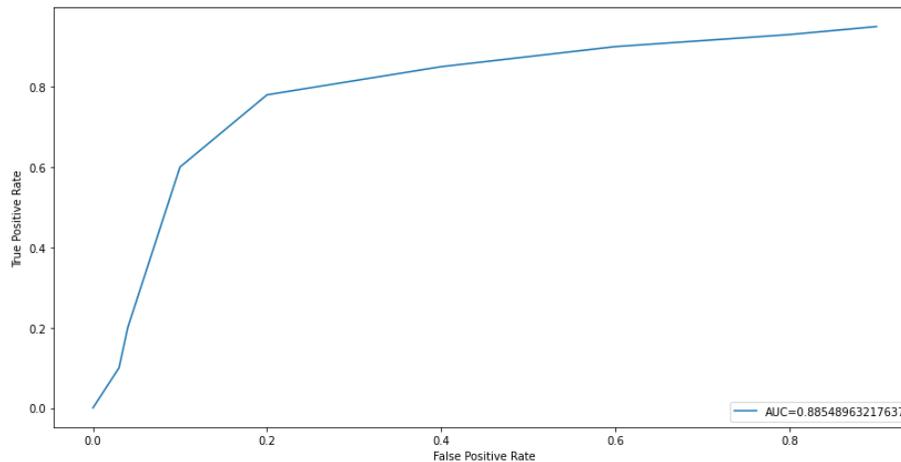


FIGURE 4.14 – Courbe ROC

Modèle	Accuracy	Precision
MLP	95%	86%
CNN	96%	83%
S-CNN	97.99%	98.75%
LSTM	94.84%	85%
CNN-LSTM	97%	96%
KNN	94%	95%
SVM	95%	96%

TABLE 4.17 – Comparaison entre différents modèles.

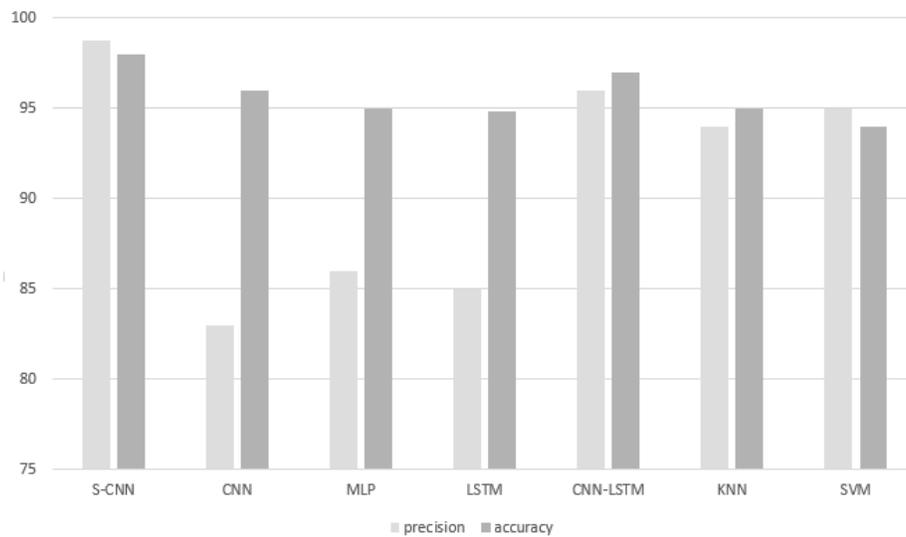


FIGURE 4.15 – Résultats obtenus

D'après le tableau 4.17 et le schéma de la figure 4.15, on remarque que le modèle S-CNN donne le meilleur résultat par rapport à d'autres modèles d'apprentissage automatique et aussi d'apprentissage profond, avec une précision de 98.75% et une précision de 97.99%.

Ce travail vise à proposer un système d'aide à la décision pour prévoir les coupures et améliorer la résilience du réseau électrique intelligent, et ces résultats prouvent et confirment que notre modèle proposé peut parfaitement prédire l'état du réseau électrique intelligent (EIG), et déterminer s'il est normal ou non.

### 4.7.2 Discussion :

Dans nos expérimentations différents modèles de machines learning et de deep learning sont utilisés comme Multilayer Perceptron (MLP), Convolutionnel neural network (CNN), Smoothed convolutionnel neural network (S-CNN), long short-term memory (LSTM), long short-term memory Network-Convolutionnel neural network (CNN-LSTM), k-nearest neighbors (KNN), Support Vector Machine (SVM).

L'exécution des modèles par google colab donne les résultats d'accuracy suivantes : 95% pour MLP, 96% pour CNN, 94.84% pour LSTM, 97% pour CNN-LSTM, 94% pour KNN, 95% pour SVM et 97.99% pour S-CNN avec le dataset qui contient 42403 composants, nous pouvons conclure de cette expérimentation que le modèle S-CNN peut marquer un bon résultat par rapport au autres modèles utilisés, durant cette exécution le phénomène de "surapprentissage (overffiting)" a été survenu, qui intervient lorsque l'algorithme apprend à partir des données mais aussi à partir des schémas et structures (patterns), ce qui conduit à obtenir un résultat de 100%, et pour régler ce problème la technique de régularisation est utilisé, elle permet de limiter ce phénomène et réduire les erreurs.

À l'opposé d'utiliser l'approche du modèle uniquement qui n'a qu'un seul état final basé sur la sortie de lui même, notre architecture du système proposée avec ses trois états distincts (EIG, EAG et EFG) a un impact significatif sur les résultats obtenus.

Prédire l'état final du réseau électrique intelligent (EFG) d'après les résultats du modèle (EIG) et le FR en premier, après cette étape on passent à la vérification de la coupure d'après les données en lignes pour déterminer l'état actuel du réseau (EAG), et le degré de danger sera déterminer à

partir des seuils (SED) Seuil état dangereux et (SEE) Seuil état extrêmement dangereux, cette division des états a une influence sur la prédiction des coupures électriques en général.

Le système surveille et prédit le comportement du réseau lors de perturbations ordinaires, permettant aux opérateurs et aux résidents de prendre les mesures nécessaires avant, pendant et après une panne de courant.

D'autres modèles d'apprentissage en profondeur peuvent être utilisés pour fournir de meilleurs résultats et améliorer les capacités de résilience du Smart Grids.

## **4.8 Conclusion**

Dans ce chapitre nous avons montré la finalité de notre travail qui représente l'implémentation du modèle S-CNN proposé dans le chapitre précédent. Nous avons aussi montré les outils utilisés dans l'implémentation suivis par les résultats obtenus des différents modèles qui prouve que le modèle proposé donne des résultats satisfaisants et peut aider à améliorer la résilience dans les Smart Grids et qui se conclut avec la discussion de ces résultats.

## Conclusion générale et perspectives

### 4.9 Conclusion générale

Nous sommes arrivés maintenant à la fin de ce mémoire, tout au long de notre travail qui consiste à créer un système décisionnel pour améliorer la résilience et la capacité des réseaux électriques intelligents et leurs permis de gérer les pannes de courant électrique qui reste toujours l'un des sujets d'actualités pour les chercheurs, à cause de leur importance à travers une prédiction des coupures électriques, pour aider les décideurs à prendre les décisions nécessaires afin de résoudre ce problème, et éviter les conséquences désastreuses comme les pertes financières, et pour cela en utilisons les modèles d'apprentissage profond.

D'abord, nous avons proposées notre architecture du système d'aide à la décision pour faire la prédiction des coupures d'électricité d'après un historique des coupures électriques qui sont collecter dans une base de données puis lui appliqué le modèle Smoothed convolutional neural network (S-CNN) pour prévoir l'état initial du smart grid et confirmer cet état à travers un facteur de risque (FR) qui est comparé avec un seuil du danger (SED), après cette étape l'état initial est confirmé (normal, anormal), et puis déclencher une alarme dans le cas anormal pour avertir les décideurs du danger attendu, passons à l'étape suivante qui représente la vérification de blackout d'après les données en lignes, en calculons le (FR) avec ces nouvelles données et comparer avec (SED) pour déterminer l'état actuel du réseau (EAG). le degré de danger sera estimer à partir des seuils

(SED) Seuil état dangereux et (SEE) Seuil état extrêmement dangereux. le système enregistre l'état actuel du réseau (EAG) dans la base de données pour une future utilisation.

Dans le cadre de la prédiction des coupures d'électricité en utilisant plusieurs modèles d'apprentissage profond comme long short term memory (LSTM) et aussi d'apprentissage automatique comme K plus proche voisin (KNN), et en mesure de faire une comparaison équitable entre tous les modèles utilisés pour prendre le modèle qui donne les meilleurs résultats, et d'après les expérimentations, on remarque que le S-CNN a donné des résultats satisfaisants par rapport aux autres modèles avec une précision de 98,75% et accuracy de 97,99 %.

Enfin, ce travail nous a permis d'approfondir nos connaissances sur la notion de la résilience des Smart Grids, et d'apprendre de nouvelles techniques concernant le Deep Learning.

## 4.10 Perspectives

D'autres modèles d'apprentissage en profondeur peuvent être utilisés pour fournir de meilleurs résultats et améliorer les capacités de résilience du Smart Grids.

L'objectif de notre mémoire était de créer un système complet pour aider les décideurs à prendre les meilleures décisions lors des coupures électriques, à partir de la prédiction jusqu'à le plan de rétablissement, qui reste un travail à faire et n'a pas été accompli, ce plan permet le smart grid de régler des pannes sans aucune intervention humanitaire.

Aussi, le modèle S-CNN doit être amélioré encore une fois, en ajoutant des couches dans le modèle et essayer de faire des modifications sur les étapes de pré-traitement car aucune modification n'a été effectuée sur la base de données.

# Bibliographie

- [1] A. Mercier, *Pilotage de la production décentralisée et des charges non conventionnelles dans le contexte Smart Grid et simulation hybride temps réel*. PhD thesis, Université Grenoble Alpes (ComUE), 2015.
- [2] S. Corsi and C. Sabelli, “General blackout in italy sunday september 28, 2003, h. 03 : 28 : 00,” in *IEEE Power Engineering Society General Meeting, 2004.*, pp. 1691–1702, IEEE, 2004.
- [3] B. L. Murphy, *Emergency management and the August 14th, 2003 blackout*. Institute for Catastrophic Loss Reduction, 2010.
- [4] X. Yu, C. Cecati, T. Dillon, and M. G. Simoes, “The new frontier of smart grids,” *IEEE Industrial Electronics Magazine*, vol. 5, no. 3, pp. 49–63, 2011.
- [5] D. Ernst, “Risque majeur de blackout : que faire ?,” *La Libre Belgique*, 2013.
- [6] T. Côme, S. Magne, and A. Steyer, “Être ou ne pas être une smart city : une étude empirique des innovations valorisées sur le site web des villes,” *Gestion et management public*, vol. 7, no. 4, pp. 73–101, 2018.
- [7] T. Nam and T. A. Pardo, “Conceptualizing smart city with dimensions of technology, people, and institutions,” in *Proceedings of the 12th annual international digital government research conference : digital government innovation in challenging times*, pp. 282–291, 2011.

- [8] A. Caragliu, C. Del Bo, and P. Nijkamp, “Smart cities in europe,” *Journal of urban technology*, vol. 18, no. 2, pp. 65–82, 2011.
- [9] N. Odendaal, “Information and communication technology and local governance : Understanding the difference between cities in developed and emerging economies,” *Computers, environment and urban systems*, vol. 27, no. 6, pp. 585–607, 2003.
- [10] R. G. Hollands, “Will the real smart city please stand up? intelligent, progressive or entrepreneurial?,” *City*, vol. 12, no. 3, pp. 303–320, 2008.
- [11] A. Khediri, *Contribution pour un Système Décisionnel Support Basé Smart Grid : Application pour les Villes Intelligentes*. PhD thesis, 2019.
- [12] M. Al-Hader, A. Rodzi, A. R. Sharif, and N. Ahmad, “Smart city components architecture,” in *2009 International Conference on Computational Intelligence, Modelling and Simulation*, pp. 93–97, IEEE, 2009.
- [13] H. Alizadeh, “Méthodes de mesures de la circulation,” 2017.
- [14] H. Lund, *Renewable energy systems : a smart energy systems approach to the choice and modeling of 100% renewable solutions*. Academic Press, 2014.
- [15] B. Mathiesen, H. Lund, K. Hansen, I. Ridjan, S. Djørup, S. Nielsen, P. Sorknæs, J. Thellufsen, L. Grundahl, R. Lund, D. Drysdale, D. Connolly, and P. Østergaard, *IDA’s Energy Vision 2050 : A Smart Energy System strategy for 100* Department of Development and Planning, Aalborg University, Nov. 2015.
- [16] T. Waghorn, “Jeremy rifkin’s third industrial revolution,” 2011.

- [17] F. Y. Melhem, Optimization methods and energy management in "smart grids". *PhD thesis, Université Bourgogne Franche-Comté, 2018.*
- [18] O. US EPA, "Electricity customers," 2015.
- [19] C. Bergaentzlé, Smart grids et efficacité des systèmes électriques : instruments de régulation et impacts de la gestion de la demande. *PhD thesis, Université Grenoble Alpes, 2015.*
- [20] T. Vijayapriya and D. P. Kothari, "Smart grid : an overview," *Smart Grid and Renewable Energy, vol. 2, no. 4, p. 305, 2011.*
- [21] S. Ullo, A. Vaccaro, and G. Velotto, "The role of pervasive and cooperative sensor networks in smart grids communication," in *MELECON 2010-2010 15th IEEE Mediterranean Electrotechnical Conference, pp. 443–447, IEEE, 2010.*
- [22] I. Tegani, Optimisation et contrôle d'un micro smart grid utilisant une pile à combustible, des supercondensateurs, des batteries, une éolienne et une source photovoltaïque. *PhD thesis, Université Mohamed Khider-Biskra, 2016.*
- [23] B. Berseneff, "Réglage de la tension dans les réseaux de distribution du futur," p. 187, 2010.
- [24] J. Colette, "Smart grids : quels impacts sur les acteurs du marché de l'énergie ?," p. 6, 2015.
- [25] X. Deschênes-Philion, "Enjeux sociopolitiques du développement des smart grids au québec : visions divergentes et contestations," 2014.
- [26] Q.-D. Ho, T. Le-Ngoc, M. Obaidat, A. Anpalagan, and I. Woungang, "Smart grid communications networks : Wireless technologies protocols issues and standards," in *Handbook of green information and communication systems, pp. 115–146, Elsevier Amsterdam, The Netherlands, 2012.*

- [27] J. B. Ekanayake, N. Jenkins, K. Liyanage, J. Wu, and A. Yokoyama, *Smart grid : technology and applications*. John Wiley & Sons, 2012.
- [28] J. Zheng, D. W. Gao, and L. Lin, "Smart meters in smart grid : An overview," in 2013 IEEE Green Technologies Conference (GreenTech), pp. 57–64, IEEE, 2013.
- [29] B. Hartono, Y. Budiyo, and R. Setiabudy, "Review of microgrid technology," in 2013 international conference on QiR, pp. 127–132, IEEE, 2013.
- [30] L. Das, S. Munikoti, B. Natarajan, and B. Srinivasan, "Measuring smart grid resilience : Methods, challenges and opportunities," *Renewable and Sustainable Energy Reviews*, vol. 130, p. 109918, 2020.
- [31] T. N. Nguyen, B.-H. Liu, N. P. Nguyen, B. Dumba, and J.-T. Chou, "Smart grid vulnerability and defense analysis under cascading failure attacks," *IEEE Transactions on Power Delivery*, vol. 36, no. 4, pp. 2264–2273, 2021.
- [32] C. W. Taylor, "Concepts of undervoltage load shedding for voltage stability," *IEEE transactions on Power Delivery*, vol. 7, no. 2, pp. 480–488, 1992.
- [33] B. Roy and R. Słowiński, "Questions guiding the choice of a multicriteria decision aiding method," *EURO Journal on Decision Processes*, vol. 1, no. 1-2, pp. 69–97, 2013.
- [34] H. A. Simon, "The new science of management decision.," 1960.
- [35] S. Oufella, D. Hamdadou, and K. Bouamrane, "Proposition d'un modèle d'aide à la négociation pour les problèmes d'aménagement du territoire," in *Actes du Cinquième Colloque sur l'Optimisation et les Systèmes d'Information COSI'2008*, p. 393, 2008.
- [36] J.-F. Lebraty, "Les systèmes décisionnels," 2006.

- [37] V. Belton and T. Stewart, Multiple criteria decision analysis : an integrated approach. *Springer Science & Business Media*, 2002.
- [38] A. Kocmanová, M. Dočekalová, and J. Luňáček, “Promethee-gaia method as a support of the decision-making process in evaluating technical facilities,” in International Symposium on Environmental Software Systems, pp. 44–53, *Springer*, 2013.
- [39] D. Ayadi, Optimisation multicritère de la fiabilité : application du modèle de goal programming avec les fonctions de satisfactions dans l’industrie de traitement de gaz. *PhD thesis, Université d’Angers*, 2010.
- [40] O. S. Vaidya and S. Kumar, “Analytic hierarchy process : An overview of applications,” *European Journal of operational research*, vol. 169, no. 1, pp. 1–29, 2006.
- [41] D. J. Power, “A brief history of decision support systems,” *DSSResources.com*, vol. 3, 2007.
- [42] P. Haettenschwiler, “Neues anwenderfreundliches konzept der entscheidungsunterstützung,” Zurich, vdf Hochschulverlag AG, pp. 189–208, 2001.
- [43] G. M. Marakas, Decision support systems in the 21st century, vol. 134. *Prentice Hall Upper Saddle River*, 2003.
- [44] N. Balacheff, “Didactique et intelligence artificielle,” *Recherches en didactique des mathématiques*, vol. 14, pp. 9–42, 1994.
- [45] J. Han, J. Pei, and M. Kamber, Data mining : concepts and techniques. *Elsevier*, 2011.
- [46] S. Sayad, An introduction to data mining. *University of Toronto*, 2011.

- [47] N. Lim, Estimation de modèles autorégressifs vectoriels à noyaux à valeur opérateur. *PhD thesis, Télécom ParisTech, 2015.*
- [48] Q.-V. Pham, M. Liyanage, N. Deepa, M. VVSS, S. Reddy, P. K. R. Maddikunta, N. Khare, T. R. Gadekallu, W.-J. Hwang, et al., “Deep learning for intelligent demand response and smart grids : A comprehensive survey,” arXiv preprint arXiv :2101.08013, 2021.
- [49] W. S. Noble, “What is a support vector machine ?,” *Nature biotechnology*, vol. 24, no. 12, pp. 1565–1567, 2006.
- [50] R. Eskandarpour, A. Khodaei, and A. Arab, “Improving power grid resilience through predictive outage estimation,” in 2017 North American Power Symposium (NAPS), pp. 1–5, IEEE, 2017.
- [51] S. Gupta, R. Kambli, S. Wagh, and F. Kazi, “Support-vector-machine-based proactive cascade prediction in smart grid using probabilistic framework,” *IEEE Transactions on Industrial Electronics*, vol. 62, no. 4, pp. 2478–2486, 2014.
- [52] C. Touzet, les réseaux de neurones artificiels, introduction au connexionnisme. *Ec2, 1992.*
- [53] C.-p. Lee and S. J. Wright, “Using neural networks to detect line outages from pmu data,” arXiv preprint arXiv :1710.05916, 2017.
- [54] S. Zarrabian, R. Belkacemi, and A. A. Babalola, “Intelligent mitigation of blackout in real-time microgrids : Neural network approach,” in 2016 IEEE Power and Energy Conference at Illinois (PECI), pp. 1–6, IEEE, 2016.
- [55] S. Demeyer, Approche bayésienne de l’évaluation de l’incertitude de mesure : application aux comparaisons interlaboratoires. *PhD thesis, Paris, CNAM, 2011.*
- [56] M. Yue, T. Toto, M. P. Jensen, S. E. Giangrande, and R. Lofaro, “A bayesian approach-based outage prediction in electric utility systems

*using radar measurement data,” IEEE Transactions on Smart Grid, vol. 9, no. 6, pp. 6149–6159, 2017.*

- [57] *G. Calas, “Etudes des principaux algorithmes de data mining,” Article de recherche cole ingnieurs en informatique EPITF, France, 2006.*
- [58] *M. R. Salimian and M. R. Aghamohammadi, “A three stages decision tree-based intelligent blackout predictor for power systems using brittleness indices,” IEEE Transactions on Smart Grid, vol. 9, no. 5, pp. 5123–5131, 2017.*
- [59] *Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” nature, vol. 521, no. 7553, pp. 436–444, 2015.*
- [60] *R. Salakhutdinov and I. Murray, “On the quantitative analysis of deep belief networks,” in Proceedings of the 25th international conference on Machine learning, pp. 872–879, 2008.*
- [61] *A. Khediri and M. R. Laouar, “Deep-belief network based prediction model for power outage in smart grid,” in Proceedings of the 4th ACM International Conference of Computing for Engineering and Sciences, pp. 1–6, 2018.*
- [62] *J. Ferber and G. Weiss, Multi-agent systems : an introduction to distributed artificial intelligence, vol. 1. Addison-Wesley Reading, 1999.*
- [63] *R. Belkacemi, A. Bababola, S. Zarrabian, and R. Craven, “Multi-agent system algorithm for preventing cascading failures in smart grid systems,” in 2014 North American Power Symposium (NAPS), pp. 1–6, IEEE, 2014.*
- [64] *M. Zimmer, Apprentissage par renforcement développemental. PhD thesis, Université de Lorraine, 2018.*
- [65] *S. Zarrabian, R. Belkacemi, and A. A. Babalola, “Reinforcement learning approach for congestion management and cascading failure pre-*

vention with experimental application,” *Electric Power Systems Research*, vol. 141, pp. 179–190, 2016.

- [66] Y. Hou, C.-C. Liu, K. Sun, P. Zhang, S. Liu, and D. Mizumura, “Computation of milestones for decision support during system restoration,” in 2011 IEEE Power and Energy Society General Meeting, pp. 1–10, IEEE, 2011.
- [67] M. Velasquez and P. T. Hester, “An analysis of multi-criteria decision making methods,” *International journal of operations research*, vol. 10, no. 2, pp. 56–66, 2013.
- [68] W. Pedrycz and S.-M. Chen, *Granular computing and decision-making : interactive and iterative approaches*, vol. 10. Springer, 2015.
- [69] S. Albawi, T. A. Mohammed, and S. Al-Zawi, “Understanding of a convolutional neural network,” in 2017 international conference on engineering and technology (ICET), pp. 1–6, Ieee, 2017.
- [70] H. Gu, Y. Wang, S. Hong, and G. Gui, “Blind channel identification aided generalized automatic modulation recognition based on deep learning,” *IEEE Access*, vol. PP, pp. 1–1, 08 2019.
- [71] S. Sakib, N. Ahmed, A. J. Kabir, and H. Ahmed, “An overview of convolutional neural network : its architecture and applications,” 2019.
- [72] H. Yakura, S. Shinozaki, R. Nishimura, Y. Oyama, and J. Sakuma, “Malware analysis of imaged binary samples by convolutional neural network with attention mechanism,” pp. 127–134, 03 2018.
- [73] H. Gholamalinezhad and H. Khosravi, “Pooling methods in deep neural networks, a review,” arXiv preprint arXiv :2009.07485, 2020.
- [74] S. S. Basha, S. R. Dubey, V. Pulabaigari, and S. Mukherjee, “Impact of fully connected layers on performance of convolutional neural net-

*works for image classification,*” *Neurocomputing*, vol. 378, pp. 112–119, 2020.

- [75] X. Xie, D. Du, Q. Li, Y. Liang, W. T. Tang, Z. L. Ong, M. Lu, H. P. Huynh, and R. S. M. Goh, “Exploiting sparsity to accelerate fully connected layers of cnn-based applications on mobile socs,” *ACM Transactions on Embedded Computing Systems (TECS)*, vol. 17, no. 2, pp. 1–25, 2017.
- [76] A. P. Wibawa, A. B. P. Utama, H. Elmunsyah, U. Pujiyanto, F. A. Dwiyanto, and L. Hernandez, “Time-series analysis with smoothed convolutional neural network,” vol. 9, no. 1, p. 44, 2022.
- [77] G. Van Rossum et al., “Python programming language.,” in *USENIX annual technical conference*, vol. 41, pp. 1–36, Santa Clara, CA, 2007.
- [78] B. Pang, E. Nijkamp, and Y. N. Wu, “Deep learning with tensorflow : A review,” *Journal of Educational and Behavioral Statistics*, vol. 45, no. 2, pp. 227–248, 2020.
- [79] T. E. Oliphant, *A guide to NumPy*, vol. 1. Trelgol Publishing USA, 2006.
- [80] R. Betancourt and S. Chen, “pandas library,” in *Python for SAS Users*, pp. 65–109, Springer, 2019.
- [81] S. Tosi, *Matplotlib for Python developers*. Packt Publishing Ltd, 2009.
- [82] O. Kramer, “Scikit-learn,” in *Machine learning for evolution strategies*, pp. 45–53, Springer, 2016.
- [83] N. Ketkar, “Introduction to keras,” in *Deep learning with Python*, pp. 97–111, Springer, 2017.
- [84] T. Carneiro, R. V. M. Da Nóbrega, T. Nepomuceno, G.-B. Bian, V. H. C. De Albuquerque, and P. P. Reboucas Filho, “Performance

*analysis of google colaboratory as a tool for accelerating deep learning applications,” IEEE Access, vol. 6, pp. 61677–61685, 2018.*