

Modélisation, analyse et prédiction de l'efficacité énergétique des centres de données

par

Hibat Allah OUNIFI

THÈSE PRÉSENTÉE À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
COMME EXIGENCE PARTIELLE À L'OBTENTION
DU DOCTORAT EN GÉNIE
Ph. D.

MONTREAL, LE 11 JUIN 2021

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC



Hibat Allah OUNIFI, 2021



Cette licence [Creative Commons](https://creativecommons.org/licenses/by-nc-nd/4.0/) signifie qu'il est permis de diffuser, d'imprimer ou de sauvegarder sur un autre support une partie ou la totalité de cette œuvre à condition de mentionner l'auteur, que ces utilisations soient faites à des fins non commerciales et que le contenu de l'œuvre n'ait pas été modifié.

PRÉSENTATION DU JURY

CETTE THÈSE A ÉTÉ ÉVALUÉE

PAR UN JURY COMPOSÉ DE :

M. Abdelouahed Gherbi, directeur de thèse
Département de génie logiciel et des technologies de l'information à l'École de Technologie Supérieure

Mme Nadjia Kara, Co-directeur de thèse
Département de génie logiciel et des technologies de l'information à l'École de Technologie Supérieure

M. Kim Khoa Nguyen, président du jury
Département de génie électrique à l'École de Technologie Supérieure

M. Mohamed Faten Zhani, membre du jury
Département de génie logiciel et des technologies de l'information à l'École de Technologie Supérieure

M. Vakilinia, Shahin, examinateur externe indépendant

M. Wubin Li, examinateur externe
Ericsson, Montréal

ELLE A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 24 MAI 2021

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

Tout au long de la rédaction de cette thèse, j'ai reçu beaucoup de soutien et d'assistance.

Je tiens à remercier tout d'abord mon directeur de thèse, Prof. Abdelouahed Gherbi, et ma co-directrice de thèse, Prof. Nadjia Kara, pour leurs confiances inébranlables pendant tant d'années. Vos commentaires perspicaces m'ont poussé à affiner ma réflexion et à amener mon travail à un bon niveau.

Mes remerciements vont également aux examinateurs, pour avoir consacré du temps et des efforts à revoir et à commenter ma thèse. Je leur suis très reconnaissant d'avoir accepté ce fardeau supplémentaire sur leurs horaires déjà chargés.

Je voudrais également mentionner Dr.Wubin Li, mon co-directeur à Ericsson, qui a suscité mon intérêt pour tout le domaine de l'efficacité énergétique des centres de données.

Mais ma plus profonde gratitude va, sans conteste, à ma famille, ma mère Mouna, Mon père Mokhtar, mes sœurs Nour-Allah et Touka Albatoul, mes frères Amenne Allah et Rayen Allah, et mon oncle Mohamed Aymen qui m'ont encouragé et soutenu tout au long de cette longue aventure. Ainsi que ma petite nièce Mina-Allah et mon petit neveu Aladin.

Modélisation, analyse et prédiction de l'efficacité énergétique des centres de données

Hibat Allah OUNIFI

RÉSUMÉ

Les applications et les technologies rendues disponibles par divers concepts et paradigmes du d'infonuagique et de l'Internet des objets, ainsi que leur combinaison, ont conduit à des volumes croissants de données à traiter, stocker et échanger. Ceci, à son tour, a conduit à un besoin croissant de centres de données (DC). Avec l'expansion rapide des DCs, de nombreux problèmes apparaissent et la consommation d'énergie élevée en est le premier. En outre, les tendances à l'augmentation de la capacité des DCs et de la consommation d'énergie par les équipements informatiques, réaffirment la nécessité de vérifier et de maintenir l'efficacité énergétique des DCs. En conséquence, les centres de données font partie des environnements les plus complexes et les plus gourmands en énergie en raison des charges internes élevées, des paramètres requis pour le maintien de basse température et d'humidité et du fonctionnement continu dans ce type d'environnements.

Les DCs sont des systèmes complexes et leur conception est une tâche d'ingénierie difficile en raison de la complexité des sous-systèmes qui le composent, ainsi que des diverses interactions et dépendances entre ces derniers. Dans ce cadre, un métamodèle DCMM (Data Center MetaModel) est proposé qui présente les différents sous-systèmes constituant l'infrastructure physique et informatique, leurs interconnexions et la structure hétérogène du DC, les principales caractéristiques, et ses différentes contraintes. Ce métamodèle est utilisé comme base pour donner une redéfinition précise et générique du PUE (Indicateur d'efficacité énergétique). Ensuite, nous analysons le comportement d'un modèle basé sur l'apprentissage automatique en profondeur pour prédire la métrique d'efficacité énergétique du centre de données (PUE). Une analyse sensible permet de fixer les paramètres clés et d'évaluer les actions de divers sous-systèmes du centre de données sur la variation du PUE.

Nous implémentons trois modèles d'apprentissage automatique en profondeur: 1) le modèle DNN avec l'algorithme propagation résilient, comme algorithme d'entraînement, 2) le modèle LSTM basé sur la technique d'attention et 3) le modèle de référence Google MLP pour fin de comparaison. L'étude comparative est basée sur trois métriques: l'erreur quadratique moyenne (RMSE), l'erreur absolue moyenne (MAE) et le coefficient de corrélation R-carré (R^2).

La validation de l'approche proposée se fait à travers des expérimentations avec des ensembles de données réels issus de deux études de cas réels. Les résultats obtenus de cette expérimentation indiquent que notre modèle basé sur l'attention LSTM proposé améliore la PUE, et par conséquent, montre sa promesse pour une mise en œuvre pratique.

Mots clés : centre de données, métamodèle, efficacité énergétique, PUE, prédiction.

Modeling, analysis, and prediction of the energy efficiency of data centers

Hibat Allah OUNIFI

ABSTRACT

The applications and technologies enabled by various concepts and paradigms of cloud computing and Internet of Things, and their combination, have led to growing volumes of data to process, store, and exchange. This in turns led to a growing need for data centers (DC). With the rapid expansion of DCs, many problems are emerging, and high energy consumption is the first. Also, trends in increasing data center capacity and energy use by IT equipment, reaffirm the need to verify and maintain the energy efficiency of DCs. As a result, DC are among the most complex and energy-intensive environments due to high internal loads, low temperature, and humidity settings, and continuous operation.

DCs are complex systems composed of Information and technology (IT) and non-IT (i.e., mechanical, and electrical) sub-systems. The variety of configurations and the inter-dependencies of the different data center sub-systems leads to enormous challenges in understanding and optimizing energy efficiency.

Designing a DC is a difficult engineering task due to the complexity of the subsystems that form it, as well as its various interactions and dependencies of different subsystems. Within this context, a metamodel DCMM (Data Center MetaModel) is proposed which presents the different sub-systems constituting the physical and IT infrastructure, their interconnections and the heterogeneous structure of DC, the main characteristics, and its various constraints. This metamodel is used as a basis to give a precise and generic redefinition of PUE. Then, we analyze the behavior of deep machine learning-based model to automatically calculate and predict the data center energy efficiency metric Power Usage Effectiveness (PUE). A sensitive analysis is used to fix the key parameters and evaluate the actions of various data center sub-systems on the PUE variation.

We implement three deep machine learning-based models: 1) DNN model with the "Resilient Back-Propagation: ReBP" algorithm as training algorithm, 2) Attention-based LSTM model and 3) Google MLP base line model for comparison. The comparative study is based on three metrics: mean square error (RMSE), mean absolute error (MAE) and the correlation coefficient R-squared (R²).

The validation of the proposed approach is done through experimentations with real datasets from two real case studies. The obtained results of this experimentation indicate that our proposed LSTM attention-based model improves the PUE, and consequently, shows its promise for a practical implementation.

Keywords: Data center, design, Metamodel, energy efficiency, PUE, prediction.

TABLE DES MATIÈRES

INTRODUCTION	1
0.1 Contexte et motivations	1
0.2 Problématique de recherches	3
0.3 Objectif de la recherche	8
0.4 Méthodologie de recherche.....	9
0.5 Organisation du rapport	14
CHAPITRE 1 REVUE DE LITTERATURE	15
1.1 Introduction.....	15
1.2 Introduction aux centres de données et notions de base	15
1.3 Architectures des centres de donnés	19
1.3.1 L'alimentation d'entrée.....	22
1.3.2 ATS (Automatic Transfer Switch).....	22
1.3.3 Système d'alimentation UPS	22
1.3.4 Suppresseur de tension transitoire (TVSS).....	24
1.3.5 PDU (Unité de distribution de puissance)	24
1.3.6 La hiérarchie des sous-systèmes des centres de données.....	24
1.3.7 Étude Critique et nos propositions de recherche.....	29
1.4 Les métriques d'efficacité énergétique	30
1.4.1 Les concepts de base.....	31
1.4.2 Les niveaux de mesure de PUE	34
1.4.3 Les limites de la métrique de PUE et contribution	35
1.5 Efficacité énergétique des centres de données : Travaux connexes	36
1.5.1 Modèles et techniques de prédiction de la température	40
1.5.2 Les méthodes d'optimisation des systèmes de refroidissement.....	45
1.5.3 Optimisation et prédiction des métriques d'efficacité énergétique	47
1.5.4 Limites et contributions.....	59
CHAPITRE 2 METHODOLOGIE DE RECHERCHE	61
2.1 Introduction.....	61
2.2 M1- métamodèle : Modélisation de Centre de Données.....	62
2.2.1 Aperçu générale de métamodèle	63
2.2.2 Modélisation de l'espace électrique.....	65
2.2.3 Modélisation de l'espace mécanique	67
2.2.4 Modélisation de l'espace TI.....	69
2.2.5 Modélisation de l'espace de control	70
2.2.6 Les contraintes de métamodèle.....	71
2.3 M2- Définition générique de la métrique d'efficacité énergétique : PUE	74
2.3.1 Les objectifs du métamodèle	74
2.3.2 Définition	76
2.3.3 Génération de modèle énergétique.....	78

2.3.4	Les paramètres de la métrique PUE.....	83
2.4	M3- Framework de prédiction de la métrique d'efficacité énergétique	88
2.4.1	Description.....	88
2.4.2	Prétraitement des données.....	91
2.4.3	Analyse de sensibilité	93
2.4.4	M3-1 : Modèle de Réseau de neurones profond (DNN).....	95
2.4.5	M3-2 : Modèle Réseau de neurones récurrent (LSTM).....	99
2.4.6	Métriques de comparaison	102
CHAPITRE 3	METAMODELE DE CENTRE DE DONNEES ET VALIDATION	105
3.1	Introduction.....	105
3.2	Métamodèle de centre de données (DCMM) et validation	105
3.2.1	Espace électrique de DCMM.....	109
3.2.2	Les contraintes OCL de modèles	112
3.2.3	Génération de modèle énergétique PFM.....	113
3.3	Conclusion	117
CHAPITRE 4	LES MODELES DE PREDICTIONS DE L'EFFICACITE	119
4.1	Introduction.....	119
4.2	Description des études de cas	120
4.2.1	Étude de cas 1 : Architecture de centre de données CLUMEQ.....	120
4.2.2	Étude de cas 2 : centre de données ITEA3 RISE Sics ICE.....	126
4.3	Les résultats numériques.....	133
4.3.1	Caractéristiques de la consommation des énergies	134
4.3.2	Résultats d'analyse de sensibilité.....	137
4.3.3	Résultats de prédiction avec DNN.....	142
4.3.4	Résultats de prédiction avec le réseau de neurone récurrent.....	146
4.3.5	Résultats de prédiction et comparaison des modèles.....	149
CONCLUSION.....		157
LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES.....		159

LISTE DES TABLEAUX

	Page
Tableau 1.1 Une taxonomie des métriques de l'efficacité énergétique pour un DC	38
Tableau 1.2 Le paramètre de sortie pour la consommation d'énergie	58
Tableau 2.1 Les différents facteurs de pondération en fonction de type d'énergie	85
Tableau 4.1 Les types d'alimentation électrique du centre de données CLUMEQ	122
Tableau 4.2 Résumé des caractéristiques de centre de données CLUMEQ	123
Tableau 4.3 Ensemble de paramètres en entrée pour l'étude de cas 1	124
Tableau 4.4 Résumé des informations de données collectées CLUMEQ DC	125
Tableau 4.5 Ensemble de paramètres en entrée pour l'étude de cas 1	131
Tableau 4.6 Résumé des informations de données collectées.....	133
Tableau 4.7 Le modèle numérique de l'architecture DNN	143
Tableau 4.8 Comparaison de la précision d'entraînement et des tests.....	144
Tableau 4.9 Comparaison de la précision d'entraînement et des tests.....	144
Tableau 4.10 Résultat de RMSE avec différentes fonctions d'activation	146
Tableau 4.11 Temps d'exécution des modèles de prédiction	153
Tableau 4.12 Temps d'exécution des modèles de prédiction	153

LISTE DES FIGURES

	Page
Figure 1.1 Les éléments de base d'un centre de données	21
Figure 1.2 Efficacité des UPS en fonction de la charge.....	23
Figure 1.3 Diagramme simplifié de flux de puissance pour un centre de données.....	27
Figure 1.4 Comment le PUE est calculé dans un centre de données	32
Figure 1.5 Les niveau de mesure de la puissance pour un centre de données	37
Figure 1.6 Les différentes métriques selon le niveau hiérarchique de DC	40
Figure 1.7 Les valeurs de PUE par niveaux de mesure selon Uptime Institute	49
Figure 1.8 Exemple d'un centre de données hétérogène	51
Figure 1.9 Les facteurs qui contribuent au PUE	52
Figure 1.10 Algorithme de réseau de neurone à trois couches	53
Figure 1.11 Exemple de réseau de neurone pour calculer PUE	54
Figure 1.12 Exemple de réseau de neurone	55
Figure 2.1 Approche proposée de définition du métamodèle	63
Figure 2.2 Définition de la métrique PUE	77
Figure 2.4 La structure de la cellule LSTM	100
Figure 3.1 Métamodèle de centre de données	106
Figure 3.2 Structures en packages de DCMM	108
Figure 3.3 Espace électrique de modèle DCMM	111
Figure 3.4 Le modèle de PFM pour le centre de données CLUMEQ.....	115
Figure 4.1 L'architecture de centre de données CLUMEQ	121
Figure 4.2 Vue d'ensemble de l'architecture de centre de données ITEA3 RISE Sics ..	127
Figure 4.3 Modèle numérique du centre de données ITEA3 RISE Sics ICE	129

Figure 4.4	Emplacement des capteurs pour collecter les données	132
Figure 4.5	Une distribution de différentes consommations d'énergie pour.....	135
Figure 4.6	Une distribution de différentes consommations d'énergie et le PUE	136
Figure 4.7	Energie totale en fonction de la température extérieure	137
Figure 4.8	Résultats de l'indice d'ordre total Sobol Paramètres du sous-système de refroidissement pour l'étude de cas ITEA3 RISE Sics DC	138
Figure 4.9	Résultats de l'indice d'ordre total Sobol Paramètres du sous-système TI.....	139
Figure 4.10	Résultats de l'indice d'ordre total Sobol.....	139
Figure 4.11	Topologie de réseau neuronal profond DNN proposée	142
Figure 4.12	Résultat de prédiction avec attention-based LSTM.....	147
Figure 4.13	Résultats de prédiction avec DNN basé BackPropagation résilient	147
Figure 4.14	Comparaison des résultats DNN basé BackPropagation résilient	148
Figure 4.15	Valeurs PUE prédites vs réelles des modèles sélectionnés	149
Figure 4.16	Valeurs PUE prédites vs réelles des modèles sélectionnés	150
Figure 4.17	Mesures de performances des modèles sélectionnés	151
Figure 4.18	Mesures de performances des modèles sélectionnés	152

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

DC	Data Center
DCMM	Data Center MetaModel
UPS	Uninterruptible Power Supply
PDU	Power Distribution Unit
ATS	Automatic Transfert Switch
TS	Transfert Switch
ML	Machine Learning
DNN	Deep Neural Network
IT	Information Technology
PUE	Power Usage Effectiveness
RMSE	Root Mean Square Error
MAE	Mean Average Error
CRAC	Computer Room Air Conditioning
LSTM	Long Short-Term Memory
MLP	MultiLayer Perceptron
IoT	Internet of Things
CLUMEQ	Consortium Laval UQAM McGill and Eastern Quebec
POD	Performance Optimized Datacenter
ReBP	Resilient Back Propagation
ENIAC	Electronic Numerical Integrator And Computer

XVIII

TIA	Telecommunications Industry Association
HVAC	Heating, Ventilation and Air-Conditioning
PFM	Power Flow Model
CRAH	Computer Room Air Handler

INTRODUCTION

0.1 Contexte et motivations

Les applications et technologies menées et dirigées par les différents concepts et paradigmes d'infonuagique et de l'Internet des objets (IdO), et leur combinaison, ont conduit à des volumes croissants de données à traiter, stocker et échanger. Également, la digitalisation et la croissance des nouvelles applications associées, comme dans le domaine de l'intelligence artificielle (IA), entraîneront une demande croissante d'infrastructures de centres de données (DC). Dans ce contexte, Ndukaife et Nnanna (2019) mentionnent que la grande quantité d'informations générées par les utilisations numériques augmente de façon exponentielle. En fait, le trafic de données a été multiplié par 4,5 entre 2013 et 2019.

Au cours des dernières années, les grandes entreprises ont migré leurs données et leurs charges de travail critiques vers le cloud. Alors que nous nous dirigeons vers la cinquième génération de systèmes de communication cellulaires (5G), les opérateurs de réseaux mobiles doivent répondre à la demande croissante de plus de bande passante et des applications très sensibles à la latence et à la disponibilité. Ainsi, ils exploitent les capacités du cloud et exécutent leurs éléments de réseau dans des ressources cloud distribuées. L'adoption de l'infonuagique par de nombreuses industries et entreprises a abouti à la prolifération des DCs...à travers le monde contenant des milliers de serveurs et d'équipements de réseau.

En conséquence, les DCs ont été présentés comme l'un des principaux systèmes pour l'industrie informatique à croissance rapide. Aujourd'hui, les grandes compagnies telles que Google®, Yahoo®, Microsoft®, Facebook, etc. proposent chaque jour une gamme de services à des millions d'utilisateurs. Ces services sont hébergés dans des DCs. En outre, les DCs ont des exigences supplémentaires qui les différencient d'une unité de calcul et de stockage. Celles-ci incluent des fonctionnalités comme l'alimentation, le refroidissement, la connectivité et la sécurité.

Également, le DC propose différents services et les caractéristiques de performance DC ont un impact significatif sur la haute disponibilité et l'évolutivité de ces services. La réduction des coûts énergétiques et l'amélioration de l'efficacité énergétique sont l'une des caractéristiques de fiabilité et l'un des grands défis auquel les gestionnaires des DCs doivent faire face. De plus, selon Qi, Zhang, et Wang (2019), la quantité d'énergie consommée par les DCs va se multiplier au cours des prochaines années. Par conséquent, l'amélioration de l'efficacité énergétique des DC est un enjeu important, non seulement pour les fournisseurs de DC, mais pour l'ensemble de l'industrie de TIC (Technologies de l'Information et de la Communication), car elle peut conduire à des économies de coûts significatives et donc créer des centres de données durables. D'où l'intérêt porté à l'efficacité énergétique dans les DCs et laquelle représente un axe de recherche très actif.

Qu'est-ce qu'un centre de données ?

Les centres de données (DC) sont des systèmes complexes, qui fournissent un environnement pour héberger des équipements informatique (IT), notamment des serveurs, des systèmes de stockage, des infrastructures réseau, ainsi que des équipements non informatiques tels que des systèmes de distribution de l'alimentation électrique et de refroidissement, etc. Pour qu'un DC fonctionne correctement, tous ses systèmes doivent être correctement configurés et intégrés.

Les DCs étant des systèmes à grande échelle et à forte consommation d'énergie, ont d'énormes budgets énergétiques, ce qui a donné lieu à divers problèmes d'optimisation de l'efficacité énergétique. La consommation d'énergie des DCs selon Dayarathna, Wen, et Fan (2015) représente environ 3% de la consommation mondiale en électricité et représente environ 2% des émissions totales de gaz à effet de serre (CO₂). Pour mettre la taille de cette consommation dans un contexte encore plus réel et clair, Dayarathna et al. (2015) indique que les 416,2 térawatt/heures d'électricité utilisés par les DCs du monde durant les dernières années ont été nettement plus élevés que la consommation totale des États-Unis qui est d'environ 300 térawatts/heures.

0.2 Problématique de recherches

Avec l'expansion rapide des DCs, de nombreux problèmes émergent et la consommation élevée d'énergie est l'un des problèmes majeurs. Dans cette section, nous décrivons les différents problèmes de notre recherche.

0.2.1 Problème de complexité des systèmes des centres de données

Le concept d'un système complexe est défini comme le système dans lequel tous les composants sont interdépendants, de sorte que l'élimination de l'un de ces composants affectera le système dans son ensemble. En effet, les systèmes complexes sont des systèmes qui dépendent de l'intégration de ses sous-systèmes et qui seront profondément modifiés si un sous-système ou une relation entre des sous-systèmes, pour une raison quelconque, est affecté. Ce qui signifie qu'il est composé de nombreux sous-systèmes qui interagissent de manière non linéaire avec l'ensemble du système évoluant au fil du temps. Cette compréhension est nécessaire et importante pour que nous puissions donner une bonne conception et créer le modèle approprié pour l'analyse et l'évaluation des DCs.

En effet, les DCs sont des systèmes complexes. En d'autres termes, l'infrastructure du DC présente un ensemble de sous-systèmes de technologie d'information (TI) et non-TI dont la relation, l'interaction et l'interdépendance entre eux sont très complexes. Notamment, l'infrastructure physique du centre de données (ou **Data Center Physical Infrastructure DCPI**) est la base sur laquelle résident les systèmes TI. C'est le pivot d'un DC, car ses éléments fournissent l'énergie, le refroidissement, l'hébergement physique, la sécurité et le câblage qui permettent aux technologies d'information (TI) de fonctionner.

La conception d'un DC est une tâche d'ingénierie difficile en raison de plusieurs facteurs :

- le DC est un système complexe en raison de ses diverses interactions et dépendances des sous-systèmes informatiques (TI) et non informatiques;

- des diverses contraintes, par exemple liées à l'environnement (tel que, l'humidité et la température externe), à l'emplacement et aux fonctions et disponibilités du système, lesquelles doivent être satisfaites lors de la conception d'un DC;
- une conception de DC devrait également satisfaire plusieurs exigences en termes de disponibilité des services, de sécurité et d'efficacité énergétique.

En outre, la puissance entrante pour alimenter un DC doit passer par un certain nombre d'étapes de transformation, de distribution de la puissance avant d'être finalement livrée à l'équipement informatique. La plus grande partie de la puissance utilisée dans l'installation est convertie en chaleur, ce qui nécessite une capacité importante des sous-systèmes de refroidissement, laquelle entraîne à son tour une charge supplémentaire sur la recirculation de l'air dans le DC. Il y a également un certain nombre de sous-systèmes auxiliaires de soutien tels que l'éclairage, les systèmes d'extinction d'incendie ainsi que les zones occupées par les administrateurs de DC.

La mise en œuvre réelle d'un DC est considérablement plus complexe que dans cette petite description. Cette dernière est donnée pour fournir une compréhension générale de la façon dont les systèmes de l'infrastructure physique de DC fonctionnent.

Malgré l'importance et la complexité de l'infrastructure physique des DC, aucun modèle à suivre n'a été développé jusqu'à date. En effet, tous les processus de fonctionnement des systèmes de l'infrastructure de DC ou l'environnement informatique doivent être clairement définis, bien documentés et normalisés de manière simple pour que tous les opérateurs et utilisateurs puissent les comprendre.

Comme chaque DC possède une architecture et un environnement unique. Un modèle personnalisé pour un système peut ne pas être applicable à un autre. Mais, un cadre de renseignement général est nécessaire pour comprendre et identifier les différents systèmes et sous-systèmes ainsi que leurs interactions.

A propos des modèles de DC, il n'y a pas de travaux qui le modélisent et donnent des détails pour tous les sous-systèmes. Et la tendance des entreprises à ne pas partager ces informations signifie que les DCs ont souvent leur conception cachée du domaine public. C'est pourquoi nous nous concentrons sur ce problème de recherche.

En outre, il n'est pas simple de modéliser le comportement exact de consommation d'énergie d'un DC que ce soit pour l'ensemble du système ou pour le sous-système individuel sans avoir un modèle approprié de conception qui détaille les différents sous-systèmes. En effet, la modélisation de la consommation d'énergie des DCs dépend de plusieurs facteurs basés sur les différentes interactions du système qui ne peuvent pas être déterminées facilement.

Avant de modéliser et d'optimiser l'efficacité énergétique des DCs, nous devrions avoir un aperçu détaillé et simplifié des différents systèmes qui font partie des modèles d'optimisation. Cet aperçu nous aidera à analyser les résultats obtenus et donner plus d'explication sur l'inefficacité de certaines zones de DC.

0.2.2 Problème de généricité de définition de la métrique d'efficacité énergétique (PUE)

Les DCs font partie des environnements les plus énergivores, en raison de charges internes élevées, de faibles réglages de température et d'humidité à l'intérieur et d'un fonctionnement continu. En effet, les installations des DCs sont caractérisées par une grande concentration d'équipements informatiques (serveurs, ordinateurs, supports de stockage de données, périphériques réseau, etc.), des générateurs de secours, des sous-systèmes UPS (Uninterruptible Power Supplies), des systèmes de refroidissement (refroidisseurs, ventilateurs, pompes, tours de refroidissement, etc.), des systèmes CRAC (Computer Room Air Conditioner) qui sont les climatiseurs des salles informatique, etc. Les équipements TI et les systèmes de chauffage, ventilation et climatisation HVAC (Heating, Ventilation and Air-Conditioning) sont les deux principaux consommateurs finaux de l'énergie.

D'ailleurs, les équipements informatiques consomment de l'énergie électrique mais génèrent également des charges thermiques internes très élevées. Par conséquent, les systèmes de ventilation consomment plus d'énergie pour évacuer la chaleur et maintenir les bonnes conditions de fonctionnement à l'intérieur. D'où les possibilités d'améliorer l'efficacité énergétique des DCs ne se limitent pas aux améliorations et aux contrôles des sous-systèmes informatiques.

À cette fin, il existe plusieurs métriques et méthodes d'évaluation qui peuvent être utilisées pour surveiller et comparer les performances des DCs, en fonction des données disponibles. Le référentiel le plus couramment utilisé est le PUE (Power Usage Effectiveness), qui a été introduit par le Green Grid. Le PUE représente la consommation d'énergie pour l'ensemble de l'installation (y compris l'équipement TI et non TI) divisée par unité livrée à l'équipement TI Jaureguialzo (2011). En effet, l'industrie de Green Grid a développé le calcul de la métrique de l'efficacité de l'utilisation de l'énergie (PUE) en 2007 comme principal moyen de mesure de l'efficacité de l'infrastructure du DC.

Même si la métrique PUE est devenue la mesure de l'efficacité des infrastructures des DCs. Le problème lié à l'identification des sous-systèmes qui font partie des mesures pour déterminer les valeurs de PUE persiste. Pour cette raison, il faut clarifier trois choses avant de se lancer dans la stratégie de mesure : i) Quels sont les sous-systèmes qui constituent les charges informatiques, ii) quels sont les sous-systèmes qui constituent l'infrastructure physique et iii) quels sont les sous-systèmes exclus de la mesure. Sans cette clarification, il peut être difficile de donner des valeurs précises de PUE.

Également, les approches traditionnelles de calcul du PUE pour les DCs ignorent l'impact de la charge de travail correspondante. Ces méthodes ne peuvent pas refléter avec précision l'efficacité énergétique à long terme des DCs. Comme la puissance consommée par le sous-système informatique et la température générée par ce sous-système augmentent normalement avec l'augmentation de l'intensité de la charge de travail, une méthode efficace utilisée pour calculer le PUE des DCs doit tenir compte des impacts de la charge de travail.

Par ailleurs, il n'existe pas de définition générique du PUE. En effet, la formule de PUE est assez générale et décrit juste l'énergie consommée par la totalité de DC et l'énergie consommée par les équipements TI sans détailler les paramètres qui doivent exister dans chaque partie (par exemple, charge de travail, la consommation des serveurs, l'utilisation des serveurs en CPU, la consommation d'énergie après les sous-systèmes des UPS, etc.). Donc, une bonne définition des différents paramètres de calculs de PUE est importante.

0.2.3 Problème de prédiction des métriques d'efficacité énergétique

Des prédictions précises de consommation d'énergie des DCs peuvent aider à mieux gérer et contrôler la consommation d'énergie des différents sous-systèmes. Cependant, en raison de la non-linéarité et de la complexité des systèmes de DCs, la prédiction de l'énergie reste un défi.

La métrique de PUE est une valeur dynamique qui peut varier, en raison de divers facteurs tels que les températures extérieures, les changements d'équipement et la charge sur les serveurs. Sans surveillance et instrumentation, il est impossible de déterminer la cause et l'effet des modifications de PUE. En effet, la métrique de PUE permet aux opérateurs de DCs d'estimer rapidement l'efficacité énergétique de leurs DCs et de déterminer si des améliorations d'efficacité énergétique doivent être apportées.

Le DC est composé des sous-systèmes électrique, mécanique, TI et de contrôle. Ces systèmes ont des interactions complexes entre eux. Le nombre élevé de configuration et l'interdépendance non linéaire des sous-systèmes créent des défis dans la compréhension et l'optimisation de l'efficacité énergétique.

De ce fait, la puissance utilisée par les sous-systèmes TI dans un DC est fournie par une série de sous-systèmes de refroidissement et de distribution d'énergie, si chacun d'entre eux présentant une inefficacité, donc une certaine quantité d'énergie est perdue.

Comme ces sous-systèmes sont généralement logés dans le DCs, leurs pertes, converties en chaleur, s'ajoutent à la chaleur produite par l'équipement informatique. Cette production thermique totale doit ensuite être gérée par les systèmes de chauffage, ventilation et climatisation (HVAC : Heating, Ventilation and Air-Conditioning).

Pour conclure, les problèmes à résoudre sont :

- les interactions entre les sous-systèmes du DC et les différentes boucles de rétroaction rendent difficile la prédiction de l'efficacité énergétique;
- le test de chaque combinaison de fonctionnalités pour maximiser l'efficacité est très important compte tenu des contraintes de temps, des fluctuations fréquentes de charges informatique et des conditions météorologiques, ainsi que la nécessité de maintenir un environnement de DC stable.

Finalement, la comparaison des performances réelles par rapport à la performance prédite pour tout ensemble de résultats donnés peut être utilisé pour l'alerte de performance automatique, les cibles d'efficacité des DCs en temps réel et le dépannage. Considéré comme une métrique de plus haut niveau pour examiner l'efficacité globale, la mesure de PUE est un excellent point de départ pour mesurer les performances du DC et suivre les modifications et améliorations à apporter au fil du temps.

0.3 Objectif de la recherche

L'objectif principal de cette recherche consiste à modéliser, prédire et analyser l'efficacité énergétique des centres de données. Cet objectif peut se résumer en deux sous-objectifs spécifiques :

- **S-OB1** : établir un métamodèle holistique et générique des DCs ainsi que les contraintes qui le définissent. En effet, le métamodèle des centres de données (Data center Meta Model : DCMM) présente les différents systèmes constituant l'infrastructure physique et

- TI, leurs interconnexions. Ce métamodèle capture la structure hétérogène des DCs, leurs caractéristiques principales et ses diverses contraintes. Ce métamodèle sera la base pour donner une redéfinition précise et générique de PUE et un langage standard et une bonne documentation d'une part pour les concepteurs des DC et d'autre part, un nouvel axe pour la recherche et développement.;
- **S-OB2** : définir un modèle de prédiction de la métrique de PUE. Ainsi qu'une analyse des résultats obtenus afin de tirer des conclusions et prendre des décisions pour améliorer l'efficacité des DCs. Ce modèle sera un plan d'action pour améliorer la consommation d'énergie d'autres sous-systèmes tels que les équipements réseau, les systèmes d'alimentation et de conversion d'énergie électrique, les systèmes du refroidissement, etc.

0.4 Méthodologie de recherche

Cette section présente la méthodologie adoptée tout au long de cette recherche. Cette méthodologie est présentée dans cette section par le biais de la méthode itérative incrémentale combinée avec la méthode PDCGO (Préparer-Définir-Concevoir-Générer-Optimiser) est utilisée pour accompagner les étapes de notre recherche.

Les résultats finaux sont une recommandation de conception holistique pour un DC. Cette première conception servira de base à des conceptions plus détaillées de centres de données à l'avenir. Ainsi qu'un modèle de prédiction de la métrique de PUE en le validant avec deux études de cas réel de DCs.

Il y a cinq étapes à effectuer, à savoir la préparation, la définition, la conception, la génération des modèles énergétique et l'optimisation y compris la partie analyse. Les explications de chaque étape sont les suivantes (voir les figures ci-dessous) :

1. Préparer : Deux études préliminaires ont été menées, à savoir des études des travaux connexes et des études sur des cas réels de DCs. En effet, des études connexes ainsi qu'un document officiel de DC de Ericsson sont utilisés pour approfondir la théorie utilisée dans

les revues de la littérature. En plus, une visite guidée d'un centre de donnée réel est utilisée pour approuver et renforcer les solutions aux problèmes existants à travers des entretiens et une observation directe d'un DC de type HPCC (High Performance Computing Center);

2. Définir: Identifier et définir les différentes contraintes et les critères liés à la conception d'un DC ce qui permet de formuler une recommandation de conception pour donner une première conception et une documentation qui servira de base à des conceptions plus détaillées de DCs à l'avenir;
3. Concevoir : à ce stade, un métamodèle de conception du centre de données (Data Center métamodèle : DCMM) est élaboré. Cette conception est basée sur des critères et contraintes de conception définis au stade de planification, de sorte qu'elle devrait produire une conception qui répond aux exigences et standards des DCs. En outre, ce métamodèle peut servir de base pour définir un langage spécifique pour soutenir les différentes parties prenantes dans la conception des DCs. Comme résultat de cette partie est la définition d'un métamodèle holistique des DCs (DCMM). Ce métamodèle capture la structure hétérogène des DCs, leurs caractéristiques principales et diverses contraintes. De plus, nous proposons une méthode pour générer un modèle de flux de d'énergie (PFM) à partir d'un modèle DC en entrée. Nous évaluons l'applicabilité de notre approche à l'aide de deux cas réels du DC CLUMEQ (Consortium Laval-UQAM-McGill et de l'Est du Québec) situé à ETS et un autre DC localisé au Suède. Une publication Ounifi, Liu, Gherbi, Lemieux, et Li (2018) a été produite afin de présenter l'idée majeure pour le problème de conception des DCs;
4. Générer : en se basant sur le métamodèle définis dans la phase de conception, on va générer des modèles énergétiques nommé PFM (Power Flow Model). En effet, nous définissons le PFM et nous détaillons les règles et les étapes pour le générer à partir de DCMM. Ceci représentera une première étape de validation de DCMM et aussi de l'objectif d'efficacité énergétique des DCs;
5. Optimiser : dans cette phase, on va définir un modèle basé sur des algorithmes d'apprentissage machine profond pour prédire l'efficacité énergétique des DCs en utilisant la métrique PUE. En effet, l'objectif principal de cette phase est d'utiliser les modèles de prédiction : i) pour valider une approche de prédiction de l'efficacité énergétique en se référant à la métrique de PUE. La validation est effectuée par des données réelles de deux

DCs, un localisé en Suède (ITEA3 RISE (Ericsson DC)) et le deuxième à Montréal (CLUMEQ DC). Trois publications Ounifi et al. (2018), Ounifi, Gherbi, Kara, et Li (2019), Liu, Ounifi, Gherbi, Li, et Cheriet (2019) ont été produites afin de présenter les progrès des travaux de recherche et les résultats obtenus. ii) Pour évaluer les actions de différents sous-systèmes de DC sur la variation de la métrique de PUE. Ensuite, nous utilisons les modèles proposés pour les analyses énergétiques et nous définissons des scénarios afin d'évaluer les actions de DC. La principale contribution de cette phase est l'utilisation des informations (par exemple, la topologie, le modèle et la consommation d'énergie) recueillies à partir d'un DC déployé pour améliorer la précision et l'applicabilité de modèle proposé.

Notre méthodologie de recherche se résume en 3 principales parties et est illustrée dans les figures 0.1 et 0.2.




Figure 0.1 Aperçu de méthodologie de recherche




Figure 0.2 Méthodologie de recherche détaillée

0.5 Organisation du rapport

Cette thèse se compose de quatre chapitres, à savoir : le premier chapitre intitulé « Revue de la littérature » dans lequel des notions de base des concepts de DCs et les méthodes et perspectives pour l'efficacité énergétique sont introduites. Ainsi qu'une étude des travaux connexes de recherche. Dans le deuxième chapitre, nous détaillons la méthodologie de recherche adoptées et les résultats visés. Le troisième chapitre présente les résultats de conception de DC en décrivant les différents constituants du métamodèle DCMM ainsi qu'un exemple de modèle de PFM avec une étude de cas réel (centre de données CLUMEQ). Le chapitre quatre de cette thèse présente les résultats d'implémentation des modèles de prédictions sélectionnés pour anticiper l'efficacité énergétique des DCs en utilisant la métrique de PUE. De plus, ce dernier chapitre assure la vérification et la validation ainsi que l'application de la présente approche dans deux cas d'études réels.

Finalement, la conclusion précise les contributions originales de cette thèse, présente une synthèse des principales limites de ce projet et propose les perspectives de recherche.

CHAPITRE 1

REVUE DE LITTERATURE

1.1 Introduction

Dans ce chapitre, nous allons définir certains concepts liés aux DCs. Ainsi que les travaux de recherches réalisés dans le domaine de DC y compris la conception, la modélisation de la consommation d'énergie, l'efficacité énergétique et les différentes techniques et méthodes utilisées pour résoudre tels problèmes. Ces travaux seront une base pour prouver nos contributions et mettre en accent la valeur ajoutée de cette recherche par rapport ce qui est existant.

1.2 Introduction aux centres de données et notions de base

Les centres de données (DC) ont commencé à fleurir dans les années 1990 avec la révolution Internet et l'inflation de la demande en connexion à haut débit, aussi bien pour le grand public que les entreprises dont les moyens informatiques en interne ne suffisaient plus. Hibat-Allah Ounifi (2015).

DiMinico et Jew (2006) indiquent que les origines des premiers DCs remontent aux années 40 et à l'existence de premiers systèmes informatiques comme l'ENIAC (l'Electronic Numerical Integrator And Computer). Ces premières machines étaient complexes à entretenir et à exploiter et disposaient d'une multitude de câbles reliant tous les composants nécessaires. Ils étaient également utilisés par l'armée - ce qui signifie que des salles informatiques spécialisées avec des supports, des chemins de câbles, des mécanismes de refroidissement et des restrictions d'accès étaient nécessaires pour accueillir tout l'équipement et mettre en œuvre les mesures de sécurité appropriées DiMinico et Jew (2006) .

A la fin des années 90, le besoin de vitesse Internet et une présence d'un réseau Internet constant pour les entreprises nécessitaient de plus grandes installations pour héberger la quantité d'équipements de réseau nécessaires. C'est à ce moment que les DCs sont devenus populaires.

Au cours de l'histoire de l'informatique, à mesure que les ordinateurs deviennent plus petits et les réseaux deviennent plus grands, le DC a évolué et s'est déplacé pour s'adapter aux technologies nécessaires de l'époque. En outre, les premiers DC avaient pour objectif d'offrir un centre d'hébergement et de traitement des données hypersensibles à des grandes entreprises internationales avec niveau de sécurité très élevé. Et la demande de DCs et la capacité augmentent rapidement Ounifi, Ouhimmou, Paquet, et Montecinos (2015).

Les DCs sont les principaux référentiels pour toutes sortes d'équipements informatiques, y compris les serveurs, les sous-systèmes de stockage, les commutateurs réseau, les routeurs et les pare-feux, ainsi que le câblage et les racks physiques utilisés pour organiser et interconnecter l'équipement informatique. Un DC doit également contenir une infrastructure adéquate, telle que la distribution d'énergie et des sous-systèmes d'alimentation supplémentaires. Cela comprend également la commutation électrique, alimentations sans coupure, générateurs de secours, les systèmes de ventilation et de refroidissement (tels que les configurations de refroidissement en ligne et les climatiseurs de salle informatique), et un approvisionnement adéquat pour la connectivité des opérateurs de réseau télécommunications. Tout cela nécessite une installation physique avec une sécurité physique et une superficie suffisante pour abriter toute la collection d'infrastructures et sous-systèmes qui le forme.

De plus, les données stockées sur les serveurs doivent être accessible à tout moment et bien protégées des problèmes extérieurs. De ce fait, les DCs ont pour avantage d'être conçus de façon à être protégés des principaux risques comme le problème d'interruption des services, ou problèmes de sécurités comme les intrusions, etc.

Il y a ainsi des protections contre les coupures électriques, les risques d'incendie, etc. Wierman, Liu, Liu, et Mohsenian-Rad (2014). Également, les DCs sont des environnements critiques pour lesquels un fonctionnement fiable et un temps d'arrêt minimum sont essentiels. Les différents composants sont interdépendants et la redondance des composants et des connexions est fondamentale.

Avec la croissance des DCs, on a un autre concept nommé la consolidation des DCs. En effet, il n'est pas nécessaire d'avoir un seul DC, et les entreprises modernes peuvent utiliser deux installations de DCs ou plus sur plusieurs emplacements pour une plus grande résilience et de meilleures performances des applications, ce qui réduit la latence en plaçant les charges de travail plus près des utilisateurs.

En outre, Kant (2009) mentionne qu'une entreprise avec plusieurs DCs peut opter pour la consolidation des centres de données, en réduisant le nombre d'emplacements afin de minimiser les coûts des opérations informatiques. La consolidation se produit généralement lors de fusions et d'acquisitions lorsque l'entreprise majoritaire n'a pas besoin des centres de données appartenant à l'entreprise subordonnée.

De plus de caractère de consolidation des DCs, DiMinico et Jew (2006) mentionnent que la redondance des différents sous-systèmes et composants de DC est très importante afin d'assurer la haute disponibilité des services offerts. Cependant, les DCs peuvent être définis par différents niveaux de fiabilité ou de résilience, parfois appelés niveaux de redondance de DCs.

En 2005, l'institut américaine ANSI (American National Standards Institute) et l'association TIA (Telecommunications Industry Association) ont publié la norme d'infrastructure de télécommunications pour les DCs (ANSI/TIA-942). Cette dernière définit quatre niveaux de conception et de mise en œuvre des DCs DiMinico et Jew (2006).

Chaque niveau est destiné à fournir plus de résilience, de sécurité et de fiabilité que le niveau précédent. Par exemple, un DC de niveau 1 est un peu plus qu'une salle de serveurs c.-à-d. pas de redondance des sous-systèmes, tandis qu'un DC de niveau 4 offre des sous-systèmes redondants et une sécurité élevée.

Dans un autre contexte, la réduction des coûts d'énergie et l'amélioration de l'efficacité énergétique des DCs est un défi pour les gestionnaires des DCs. En effet, la quantité d'énergie consommée par les centres de données - qui sont des entrepôts pour des milliards de gigaoctets d'informations - va se multiplier au cours des prochaines années, mettant une énorme pression sur l'approvisionnement en énergie Jin, Zhang, Vasilakos, et Liu (2016). D'où l'énergie est une préoccupation de premier ordre dans la conception de ces systèmes.

Pour conclure, nous citons ci-dessous la liste des avantages généralement identifiés pour les DCs :

- le DC réduit les coûts et risques liés aux technologies de l'information;
- le DC fournit des installations de données et une infrastructure réseau de haute qualité;
- l'augmentation immédiate de la fiabilité et de l'évolutivité du réseau. À mesure que l'entreprise se développe et nécessite davantage de ressources réseau, les DCs peuvent facilement répondre à des nouvelles exigences;
- les services gérés par le DC fournissent des personnels informatiques compétent et facilement disponible pour l'exploitation, la surveillance et la maintenance du système;
- les services gérés par les DCs permettent un fonctionnement continu, sécurisé, et une disponibilité 24h/7 jours.

Dans les prochaines sections et sous-sections de ce chapitre, nous allons détailler les différentes architectures des DCs ainsi que la métrique la plus utilisée afin d'évaluer l'efficacité énergétique de la totalité de DCs. Tout ce que nous allons présenter dans les prochaines sections sera illustré avec des travaux connexes et des revues de la littérature.

1.3 Architectures des centres de donnés

En raison de leur coût et de leur nature critique, les DCs doivent être conçus, construits et exploités pour répondre aux principaux indicateurs de performance requis. Cependant, les exigences minimales spécifiées dans les normes ne se traduisent pas en meilleures pratiques lorsque l'objectif est d'atteindre la fiabilité la plus élevée possible, avec la qualité de service requise et les objectifs d'efficacité énergétique.

La conception du DC se concentre sur de nombreux aspects tels que la sélection du site, la conception des installations, le matériel informatique, le refroidissement, le réseau, la distribution d'énergie, etc.

Étant donné qu'une installation informatique peut contenir un grand nombre de serveurs, une grande quantité d'infrastructure peut être nécessaire pour prendre en charge la capacité informatique du DC. En particulier, une grande quantité des sous-systèmes (équipement d'infrastructure de câblage, d'équipement d'infrastructure de communication réseau, etc.) peut être requise pour prendre en charge à tout moment des opérations informatiques par des serveurs dans un DC.

Pour un projet de DC réussi, certains paramètres doivent être maintenus en priorité et planifiés efficacement. Cela inclut des caractéristiques telles que la fiabilité, la disponibilité, la facilité de maintenance, la capacité, les plans d'évolutivité et de croissance. Ces facteurs aideront l'équipe de conception à concevoir efficacement un centre de données répondant aux besoins des entreprises et des clients requis.

Le facteur fiabilité de conception des DCs et essentiellement la conception de l'infrastructure de base des DCs est très important. En effet, la fiabilité du DC est définie par les performances de l'infrastructure. Comme les informations sont envoyées dans les deux sens avec les clients utilisant les DCs, d'énormes flux de données sont transférés vers et depuis les systèmes TI avec des débits de données extrêmement élevés.

L'infrastructure doit constamment prendre en charge le flux de données sans erreurs qui provoquent une retransmission et des retards.

En plus de facteur de fiabilité, d'autres facteurs importants doivent être pris en considération lors de la conception des DCs. En effet, la définition des standards de conception est très importante pour avoir une base solide lors de conception de n'importe quel modèle de DCs. Dans ce cadre, TIA-942 (Telecommunications Infrastructure Standard) et selon les travaux de DiMinico et Jew (2006); Association (2010) et Govindan, Minei, Kallahalla, Koley, et Vahdat (2016) décrivent le standard à respecter pour la conception de base des DCs. Ce standard spécifie les exigences et les directives pour les infrastructures des DCs. Elle couvre le câblage, la sélection du site, l'espace et la disposition pour la conception de l'infrastructure de DCs.

Également, il y a le facteur de refroidissement des DCs tel que bien discuté par Cho et Kim (2016). Les serveurs et les équipements tels que les équipements de télécommunications, de réseaux, de interrupteurs et d'autres équipements électroniques disposés dans des baies (Racks), deviennent de plus en plus petits et plus puissants pour répondre aux besoins d'installation de DCs à haute densité. Cependant, cela concentre une énorme quantité de chaleur dans une zone plus petite. Un équipement de refroidissement adéquat est indispensable, ainsi que l'utilisation d'une configuration d'allée chaude et d'allée froide où les racks sont disposés en rangées alternées d'allées chaudes et froides. Cette pratique permet à l'air froid de l'allée froide de se propager sur l'équipement où il est ensuite expulsé par l'arrière dans l'allée chaude.

La chaleur générée par de tels équipements électroniques est refroidi à l'aide d'unités de refroidissement, telles que les climatiseurs de la salle informatique (CRAC : Computer Room Air Conditioners) ou les gestionnaires d'air de la salle informatique (CRAH : Computer Room Air Handlers) pour une gestion thermique efficace.




Figure 1.1 Les éléments de base d'un centre de données
Tirée de Govindan et al. (2016)

Selon Y. Tarutani et al. (2016), les systèmes formant l'infrastructure des centres de données sont les suivants :

- source (s) d'alimentation électrique,
- générateur de secours et commutateur de transfert automatique (ATS : Automatic Transfert Switch),
- les sous-systèmes UPS (Uninterruptible Power Supply) et les sous-systèmes de maintenance,
- unité de distribution de puissance (PDU) pour alimenter la totalité des équipements informatique,
- les unités de PDU au niveau de baies (Racks),
- l'alimentation interne des serveurs,
- les racks contenant des serveurs et des systèmes réseaux, etc.

Dans ce qui suit, nous allons détailler les différents sous-systèmes ainsi que leurs fonctionnalités et utilités dans les DCs.

1.3.1 L'alimentation d'entrée

La source d'énergie électrique est livrée à un DC par une société de services publics locale. Une fois que l'alimentation électrique entre dans le bâtiment, son premier arrêt sera habituellement le sous-système l'ATS (Automatic Transfer Switch). Cette alimentation présente l'alimentation de base pour la totalité de DC.

1.3.2 ATS (Automatic Transfer Switch)

Un périphérique qui transfère automatiquement une alimentation de sa source principale vers une source de secours lorsqu'elle détecte une panne dans la source principale. Lorsqu'une défaillance ou un problème se produit dans un système d'alimentation primaire, l'ATS invoque une source d'alimentation de secours, comme le sous-système UPS (Uninterruptible Power Supply), qui offre une alimentation sans interruption.

1.3.3 Système d'alimentation UPS

UPS (Uninterruptible Power Supply) est un périphérique qui permet aux systèmes des DCs de continuer à fonctionner pendant au moins un court moment lorsque la source d'alimentation principale est perdue. Karpati, Zsigmond, Vörös, et Lendvay (2012) indiquent que les systèmes UPS ne sont pas utilisés que pour la gestion des pannes de courant émergentes. Il fournit également une protection contre les surtensions. Ainsi, il contient une batterie qui prend la charge lorsque l'appareil détecte une perte de puissance de la source principale.

Également, les dispositifs de stockage d'énergie (les batteries d'UPS) sont les principaux composants pour les conceptions récentes de DCs à faible consommation d'énergie. Premièrement, Karpati et al. (2012) et Botterón et Pinheiro (2007) mentionnent que les batteries d'UPS permettent aux DCs de sous-provisionner intentionnellement l'infrastructure de distribution d'énergie. Lorsqu'une augmentation de la demande de puissance de charge survient, on peut libérer temporairement l'énergie stockée de l'UPS pour éviter une violation du budget d'alimentation.

Deuxièmement, les dispositifs de stockage d'énergie facilitent également l'intégration des énergies renouvelables émergentes dans les DCs.

Principalement, les sous-systèmes UPS sont intégrés au niveau des installations du DC et ne sont pas utilisés que pour la gestion des pannes de l'alimentation émergentes. Karpati et al. (2012) indiquent qu'il existe trois principaux types de topologies d'UPS spécifiées par la norme de la Commission électrotechnique internationale (CEI-62040) Commission (2016): UPS de secours, UPS interactif en ligne et UPS en ligne à double conversion. Chaque UPS convertit l'entrée de courant alternatif (CA) en courant continu (CC) par un redresseur. Les batteries de secours stockent de l'énergie pour l'utiliser dans une panne dans la source d'alimentation principale.

Comme tout système électrique, les UPS présentent des pertes. Ces pertes vont avoir de l'impact sur l'efficacité énergétique des DCs. La figure ci-dessous présentée par Rasmussen (2006) prouve la variation des pertes des UPS en fonction des charges des DCs.




Figure 1.2 Efficacité des UPS en fonction de la charge
Tirée de Rasmussen (2006)

1.3.4 Suppresseur de tension transitoire (TVSS)

Le sous-système supprimeur de tension transitoire TVSS (Transient Voltage Surge Suppressor) permet d'éliminer et de réduire les dommages aux équipements de traitement de données et autres équipements critiques en limitant les tensions transitoires (surtensions) et les courants (surtensions) sur les circuits électriques.

1.3.5 PDU (Unité de distribution de puissance)

C'est un dispositif de contrôle de l'alimentation électrique dans un DC. En effet, après avoir protégé et nettoyé la puissance, l'alimentation de UPS circulera vers un groupe d'unités de distribution d'énergie (PDU). À ce stade, la tension sera normalement 480VCA qui est trop élevée pour la plupart des équipements informatiques. L'unité de distribution de puissance (PDU) doit convertir les 480 volts en une tension plus utilisable comme 120VCA ou une autre tension selon le standard définis pour alimenter les équipements informatiques (TI). Hsu et Geng (2014).

1.3.6 La hiérarchie des sous-systèmes des centres de données

Comme présenté précédemment, les principaux sous-systèmes formant l'infrastructure physiques des DCs. Nous allons détailler dans cette section la hiérarchie de ces sous-systèmes au sein de DC et leurs interconnexions. Ce qui va nous donner un aperçu sur la conception des DCs.

Dans la revue de la littérature, il existe de nombreux travaux qui définissent et présentent l'infrastructure des DCs. Mais, chaque recherche prend chaque partie du DC d'un seul point de vue. En outre, les DC ont souvent leur conception cachée du domaine public, ce qui crée plus de défis. Egalement, La conception des centres de données étant une source d'avantage concurrentiel et les informations sur les DCs modernes sont rares.

L'infrastructure physique des DCs représente la base pour faire fonctionner sans interruptions, les systèmes de TI. En effet, cette infrastructure est composée par un ensemble de sous-systèmes formant la base des systèmes énergétiques des DCs. Le DC est un environnement conçu pour héberger des équipements informatiques au sommet d'une infrastructure solide (systèmes d'alimentation, systèmes de refroidissement et systèmes de contrôle). La mise en œuvre réelle d'un DC est plus complexe que celle déjà décrite dans les travaux de littérature.

Les centres de données sont composés de trois infrastructures principales : les sous-systèmes informatiques, de refroidissement et de l'alimentation électrique. Krein (2017); Wierman et al. (2014) prouvent que pour fonctionner correctement, le DC doit disposer d'une infrastructure adéquate (avec un sous-système de distribution électrique, un réseau électrique, des réserves d'énergie, des générateurs dédiés à la sauvegarde, un sous-système de ventilation et de refroidissement, et une puissante connexion Internet). Une telle infrastructure nécessite un espace physique suffisant et sécurisé.

Dans ce contexte, Avgerinou, Bertoldi, et Castellazzi (2017); Snevely (2002) définissent les concepts et la conception d'un exemple de DCs en se focalisant essentiellement sur la conception des systèmes énergétiques qui représentent une partie importante des sous-systèmes de l'infrastructure des DCs.

Ces travaux sont une ligne directrice qui doit être prise en considération lors de la conception du DC. Mais ça représente qu'un seul cas de DC, non généralisable.

Dans un autre point de vue pour la conception DC, Whitted et Aigner (2007); Maselli, Blessington, et Stein (2018) décrivent les approches modulaires de conception afin d'aider les responsables informatiques à construire une analyse de rentabilisation pour un remplacement ou une modernisation de leur conception de DC.

Avant d'aller plus loin dans la conception des DCs, nous allons donner un aperçu sur la hiérarchie des différents systèmes formant le DCs pour qu'on puisse tirer vers la fin de cette

section les valeurs de nos contributions tout en critiquant les limites des travaux actuels pour la conception des DCS.

La puissance entrante dans un DC via une station d'alimentation d'entrée (Utility power) représente la source d'alimentation principale. Les DCs utilisent également une unité de générateur diesel (DG) qui est utilisé comme une source d'alimentation de secours lors d'une panne de la source principale. Un commutateur de transfert automatique (ATS) est utilisé pour sélectionner automatiquement entre ces deux sources. Y. Tarutani et al. (2016).

Lors d'une panne de la source principale d'alimentation, l'ATS tente de passer à l'alimentation DG, il faut environ 10-20 secondes (appelé comme temps de démarrage) pour que le DG soit activé avant de pouvoir alimenter. Les unités d'alimentation (UPS) sont généralement utilisées pour combler cet écart de temps entre la panne de la source d'alimentation d'entrée et l'activation de la DG. Les unités UPS stockent de l'énergie (chargées pendant la disponibilité de l'alimentation) en utilisant des batteries qui ont généralement un temps d'exécution (niveau de charge de réserve) d'environ 10 minutes pour alimenter le DC durant cette transition. Les serveurs de données emploient typiquement des UPS à double conversion, qui ont un temps de transfert nul (contrairement à UPS de secours) lors d'une panne de la source principale d'utilité. Dans un UPS à double conversion, la puissance entrante est toujours convertie de courant alternatif (CA) à un courant continu (CC) (pour se stocker dans les batteries) et est de nouveau convertie de CC à AC (pour alimenter les équipements TI) Karpati et al. (2012) ; Kontorinis et al. (2012).

Étant donné que les UPS sont toujours impliqués dans ce processus de double conversion (même s'ils ne sont pas utilisés pour alimenter le DC), leur défaillance rendra l'ensemble du DC indisponible. La puissance des unités UPS est alimentée à plusieurs unités de distribution d'alimentation (PDU) dont les tailles sont généralement comprises entre 100-200 KW. Finalement, les PDUs ont des transformateurs qui abaissent la tension et l'alimentation pour alimenter plusieurs racks, chacun abritant des sous-systèmes de technologie d'information (TI) Hsu et Geng (2014).

La figure ci-dessous (Figure 1.3) tirée de l'article de Cho et Kim (2016) présente l'un des exemples de flux énergétique, indiquant les éléments de base de systèmes énergétique d'un DC ainsi que les liens qui existent entre eux.




Figure 1.3 Diagramme simplifié de flux de puissance pour un centre de données
Tirée de Cho et Kim (2016)

Les sous-systèmes des DCs peuvent être traités en fonction de plusieurs niveaux :

- niveau utilitaire : Les flux indépendants, la cogénération et les énergies renouvelables externes sont quelques exemples de défis en dehors d'un centre de données lui-même;
- niveau du bâtiment : Il s'agit du niveau auquel l'alimentation principale du service public entre dans l'installation. Les défis comprennent le choix entre l'entrée basse tension (par exemple 480 V ou 600 V) et l'entrée à moyenne tension, et si l'alimentation principale du DC doit être convertie immédiatement en courant continu;
- niveau de sauvegarde : De nombreuses architectures ont des alimentations sans coupure (UPS) et des générateurs à carburant pour fournir de l'énergie au niveau du DC. Certains DCs distribuent la sauvegarde à des niveaux inférieurs;
- niveau rack : Les groupes de racks sont susceptibles d'utiliser une gestion thermique plus large, mais la fourniture d'énergie aux racks individuels est typique.

Chaque niveau implique des besoins et des opportunités d'alimentation particuliers.

Bien qu'un système optimisé puisse coupler des attributs à plusieurs niveaux pour obtenir les meilleurs résultats, on mettra l'accent sur les niveaux individuels et les défis que chacun implique.

Comme présenté précédemment, les différents systèmes et sous-systèmes formant l'infrastructures physique et TI des DCs. Des travaux ont présenté certains modèles de conceptions des DCs mais ils se focalisent plus sur la modélisation des systèmes énergétiques.

Dans ce même contexte, Guérout et al. (2013); Ponsard et Deprez (2015) et Ponsard, Deprez, et Michel (2015) proposent un modèle de conception à base de langage UML (Unified Modeling Language). Le modèle proposé présente un profil UML pour la conception éco-énergétique des applications cloud. En effet, la présentation UML simplifie la vue au niveau de l'application et aide à définir la consommation d'énergie et les mesures pour les services Cloud.

Dans un autre point de vue, Sondur, Ray, Biswas, et Kant (2017) définissent un modèle basé sur UML pour concevoir les sous-systèmes réseau du DC en proposant un modèle pour la gestion de l'énergie des réseaux DC. Ils utilisent NS3 (Network simulator) pour avoir une simulation d'une architecture réseau de DC et améliorer les résultats d'efficacité énergétique de l'architecture réseau.

Aussi, Rygielski, Kounev, et Zschaler (2013) définissent un modèle conceptuel pour la modélisation des performances des infrastructures de réseaux dans les DCs modernes. Chaque modèle proposé présente respectivement la configuration, le trafic et la structure du réseau du DC. En effet, le méta-modèle proposé a été conçu pour relever les défis de l'analyse des performances du réseau dans les DCs modernes tout en couvrant les aspects importants liés aux performances des infrastructures réseau.

Également, Rygielski et al. (2013) montrent à travers un exemple comment les modèles d'infrastructure réseau peuvent être automatiquement transformés en modèles de simulation OMNeT¹ pour obtenir une évaluation quantitative des performances des réseaux.

1.3.7 Étude Critique et nos propositions de recherche

Notre travail est différent des travaux connexes en ce qu'il présente un métamodèle générique pour un DC en décrivant les différents systèmes et les principales contraintes de conceptions.

La proportionnalité énergétique est importante, mais l'architecture complète du système est également importante. Pour le second, le lien entre les puissances électriques et la conception numérique est important.

À notre connaissance, aucun n'a encore présenté les systèmes DC interactions et interdépendances. La plupart des travaux de recherche présentés dans la littérature et mentionne dans les sections précédentes se concentrent sur une partie de conception de DC et bien évidemment en se limitant à un besoin particulier (exemple. La conception des sous-systèmes réseaux, les sous-systèmes de refroidissement). En effet, les DCs ont été conçus comme des couches indépendantes, les composants critiques, tels que les systèmes UPS, les climatiseurs de salle informatique (CRAC), l'équipement de distribution électrique, les racks d'équipement et les systèmes ICT ont été dimensionnés séparément, sans voir comment ils pourraient tous s'emboîter comme un système cohérent. De même, les bâtiments dans lesquels de nombreux DCs sont hébergés n'ont pas été conçus pour fournir l'environnement robuste requis pour soutenir et protéger les opérations critiques. Donc, il serait souhaitable de fournir une conception générique et assez générale d'une structure complète qui peut être facilement adaptée pour l'unité de construction modulaire et facilement configurée pour divers besoins relatifs aux nouveaux sous-systèmes à intégrer plus tard.

¹ Un environnement de simulation d'événements discrets. Principalement concentré sur les réseaux de communication. Varga (2010)

Une telle conception serait facilement assemblée et configurée pour fournir une structure qui peut être rapidement mise en œuvre un DC.

Nous nous concentrons sur la résolution de la complexité de la conception de l'architecture DC par une approche de conception, qui permet d'évaluer par la suite l'efficacité de l'utilisation de l'énergie à travers la génération de plusieurs exemples des DCs. À cette fin, nous proposons un métamodèle générique de centre de données (DCMM), qui définit les abstractions pour capturer la structure de l'infrastructure physique des DCs avec leurs interdépendances, contraintes et exigences pertinentes.

1.4 Les métriques d'efficacité énergétique

Compte tenu des fortes demandes énergétiques, l'amélioration de l'efficacité des DCs est un problème important à la fois dans les recherches et dans l'industrie, car elle peut entraîner d'énormes économies de coûts.

Il est difficile de définir l'efficacité énergétique d'un système complexe tel qu'un DC. L'efficacité énergétique est généralement définie sur la base d'offrir des meilleurs services avec moins d'énergie, mais pour les DCs, l'efficacité énergétique est difficile à mesurer et varie selon les applications offertes et les demandes croissantes en fonction de temps. Pour cela, les opérateurs de DCS ont besoin des standards et des métriques afin d'avoir une vision et un suivi des différents sous-systèmes, de les rendre plus énergétiques et de les au même temps exploiter de manière optimale. Dans ce cas, l'une des métriques la plus populaire et la plus utilisée pour évaluer l'efficacité de la totalité de DC y compris l'infrastructure physique et les équipements TI est le PUE (Power Usage Effectivess) définis par **Green Grid**.Jaureguialzo (2011).

Afin de mieux comprendre cette métrique, nous allons présenter dans les sous-sections qui suivent les concepts de bases liés à cette métrique ainsi que les travaux de recherche effectués pour calculer et évaluer cette métrique.

1.4.1 Les concepts de base

En raison du développement croissant des technologies vertes, les entreprises tentent d'atteindre un objectif d'efficacité énergétique. Pour une conception meilleure et robuste, il est recommandé de fixer les objectifs d'efficacité pendant la phase de conception elle-même. Pour cette fin, plusieurs métriques ont été définies et la métrique la plus utilisée est PUE. La question qui se pose à ce niveau est : Pourquoi tout ce besoin d'une plus grande efficacité énergétique ?

Étant donné que l'énergie et le refroidissement des DCs sont deux des plus grands problèmes auxquels les organisations informatiques d'aujourd'hui sont confrontées. De nombreuses entreprises traditionnelles migrent leurs données à la forme numérique et tirent parti de la technologie en tant qu'un moyen clé pour la croissance et l'évolution technologique des entreprises. Cette migration a créé à son tour un besoin pour des DCs plus grands et bien évidemment énergétiquement efficaces. Donc, un DC énergétiquement efficace est une priorité.

En effet, avec des DCs plus efficaces, les organisations de TI peuvent mieux gérer les demandes accrues des équipements informatiques (équipements réseaux, calculs, stockage, etc.) avec des coûts réduits d'énergie et tout en restant compétitif et capable de répondre aux besoins commerciaux futurs.

C'est quoi l'Indicateur d'efficacité énergétique PUE ?

Selon Avelar, Azevedo, French, et Power (2012); Jaureguiualzo (2011), le PUE est la relation entre l'énergie totale entrant dans un DC et l'énergie utilisée par l'équipement informatique à l'intérieur du DC. La figure ci-dessous décrit la formule pour calculer le PUE.




Figure 1.4 Comment le PUE est calculé dans un centre de données
Tirée de Avelar et al. (2012)

L'énergie totale est définie comme l'énergie dédiée pour alimenter uniquement le DC. En effet, cette énergie totale qui sera mesurée à l'entrée de DC et qui permet d'alimenter les éléments ci-dessous :

- les sous-systèmes de distribution d'énergie, y compris les systèmes UPS, les appareillages de distribution, les générateurs, les unités de distribution d'énergie (PDU) et les batteries de secours en cas de panne;
- les sous-systèmes de refroidissement, tels que les refroidisseurs, les tours de refroidissement, les pompes, les unités de traitement de l'air de la salle informatique (CRAH), les climatiseurs de la salle informatique (CRAC) et les unités de traitement d'air;
- autres charges divers, telles que les systèmes d'éclairage des centres de données.

Alors que l'énergie des équipements informatiques (TI) est définie comme l'énergie consommée par l'équipement utilisé pour gérer, traiter, stocker ou acheminer des données. En effet, l'énergie des équipements informatiques comprend l'énergie associée à tous les équipements informatiques (p. Ex., Équipements de calcul, de stockage et de réseau) ainsi que des équipements supplémentaires (Commutateurs KVM (Kernel Virtual Machine), moniteurs et postes de travail ou ordinateurs portables utilisés pour surveiller ou contrôler le DC).

Également, Avelar et al. (2012) indique que la métrique PUE est une excellente mesure pour comprendre dans quelle mesure un DC fournit de l'énergie à son équipement informatique. La mesure est mieux appliquée pour examiner les tendances d'une installation au fil du temps et mesurer les effets des différentes décisions de conception et d'exploitation au sein d'une installation spécifique. D'où l'importance de cette métrique. Dans ce même contexte Sharma et al. (2017) mentionnent que les DCs modernes utilisent des techniques de conception et d'optimisation pour atteindre des valeurs de PUE (Power Usage Effectiveness) aussi basses que 1,1.

En outre, la métrique PUE peut aider les propriétaires et les opérateurs de DCs à mieux comprendre et améliorer l'efficacité énergétique de leurs DCs existants et les aider aussi à prendre de meilleures décisions sur les nouveaux DC à déployer.

Et de ce fait, PUE présente un moyen pour déterminer :

- les possibilités d'améliorer l'efficacité opérationnelle d'un centre de données;
- la possibilité que les opérateurs du centre de données améliorent les conceptions et les processus au fil du temps;
- possibilités de réutiliser l'énergie pour des équipements informatiques supplémentaires;
- une cible ou un objectif de conception pour les nouveaux centres de données.

L'évaluation des valeurs de calculs de PUE indique l'allocation et la répartition énergétique dans un DC. Par exemple, un PUE de 3.0 indique que l'utilisation totale d'énergie du DC est trois fois supérieure à la consommation d'énergie pour l'équipement informatique tout seul. Avelar et al. (2012) mentionnent que les valeurs PUE peuvent aller de 1,0 à l'infini. Idéalement, une valeur PUE proche de 1,0 indiquerait 100% d'efficacité (c'est-à-dire que toute l'énergie est utilisée uniquement par les équipements informatiques).

Certains travaux de recherche tels que les travaux de Sheehan (2013), Jaureguialzo (2011), Dayarathna et al. (2015), Avgerinou et al. (2017), Maselli et al. (2018) indiquent que de nombreux DCs peuvent avoir un PUE de 3,0 ou plus, mais, avec une conception appropriée, une valeur PUE de 1,6 (ou meilleure) devrait être réalisable. Ceci est validé par des mesures effectuées par *Lawrence Berkeley National Labs*, qui Montrent que 22 centres de données ont eu des valeurs PUE dans la plage de 1,3 à 3,0.

Des grandes industries tels que Google et Microsoft créent des DCs pour des PUE de 1,2 ou mieux. Mais ce sont des leaders de l'industrie. Ce qui n'est pas le cas pour d'autres industries des DCs. En effet, selon *Uptime Institute Stansberry (2017)*, un centre de données américain moyen a un PUE de 2,5. Cependant, les DCs avec un PUE de 3,3 et plus sont également fréquents. Cela signifie que seulement 1/3 de toute l'énergie consommée par les DCs est utilisée par les équipements informatiques et 2/3 de cette énergie est gaspillée.

1.4.2 Les niveaux de mesure de PUE

Une approche à trois niveaux pour mesurer PUE. Il existe trois niveaux de mesure avec le PUE : niveaux 1, 2 et 3 (basique, intermédiaire et avancé). À chaque niveau, la charge informatique est mesurée dans différentes zones - les sorties UPS, les sorties PDU et directement à partir de l'équipement informatique, respectivement. Il est également recommandé que chaque niveau de PUE soit mesuré à différents intervalles - hebdomadaire, horaire et 15 minutes ou moins, respectivement.

Selon Avelar et al. (2012), Le niveau 1 (L1), il est caractérisé par :

- la charge informatique est mesurée à la sortie de UPS et peut être lue à partir du panneau de UPS, à travers un équipement de mesure sur la sortie de UPS;
- l'énergie entrante est mesurée à partir de l'entrée de DC qui alimente tous les équipements électriques et mécaniques utilisés pour alimenter et refroidir le centre de données;
- le contrôle de base nécessite la collecte des mesures de puissance une fois par mois.

Pour le niveau 2 (L2), il est caractérisé par :

- la charge informatique est mesurée à la sortie des PDUs dans le centre de données et peut généralement être lue à partir du panneau avant PDU ou à travers un compteur au niveau du transformateur PDU;
- l'énergie entrante est mesurée à partir de l'entrée qui alimente tous les équipements électriques et mécaniques utilisés pour alimenter et refroidir le centre de données;
- la surveillance intermédiaire nécessite la collecte des mesures de puissance une fois par jour.

Finalement, le niveau 3 (L3) est caractérisé par :

- une charge informatique est mesurée à chaque pièce individuelle d'équipements informatiques dans le centre de données, soit par des PDU de rack;
- l'énergie entrante est mesurée à partir de l'entrée de DC (source d'alimentation primaire) qui alimente tous les équipements électriques et mécaniques utilisés pour alimenter et refroidir le centre de données;
- la surveillance avancée nécessite, au minimum, la collecte des mesures de puissance une fois toutes les 15 minutes ou moins.

1.4.3 Les limites de la métrique de PUE et contribution

Tout en considérant deux DCs dans deux localisations différentes avec les mêmes systèmes (informatique, distribution d'énergie, générateurs, UPS, etc.), mais avec des systèmes de refroidissement différents. Dans le cas où ils ont les mêmes valeurs PUE, cela signifie que leurs infrastructures de refroidissements (toutes autres étant égales par ailleurs) utilisent les mêmes quantités d'énergie. Cependant, un DC situé dans un climat très froid, profitant d'un refroidissement externe, plutôt qu'un DC situé dans un climat plus chaud.

Avec cette température plus basse, il serait plus efficace dans la consommation électrique du DC situé dans la région chaude.

Pour conclure, que la définition standard de PUE ne prend pas en considération les températures externes et les conditions météorologique tout au long de l'année. Dans ce cas, et comme deuxième contribution pour notre recherche est la définition plus détaillée de PUE. De ce fait, une nouvelle métrique vraiment précise proposée permettant de concevoir l'efficacité de l'utilisation d'énergie. Cette métrique mettra l'accent sur les caractéristiques environnementales extérieures du DC, en étudiant les caractéristiques météorologiques et géothermiques.

Un autre facteur influençant la variation des valeurs de PUE est la charge informatique des équipements TI. En effet, la charge informatique peut varier d'un moment à l'autre en raison de besoins informatiques instantanément différents, tandis que le retrait, l'ajout ou le remplacement d'équipement informatique peut également entraîner des modifications permanentes de la charge informatique. Dans tous les cas, l'efficacité énergétique est fortement affectée par la charge informatique. À mesure que la charge informatique installée augmente, bien que l'énergie consommée augmente également, le PUE a tendance à être plus faible. Cela signifie que si un DC bien conçu connaît un PUE plus élevé que prévu, une explication possible pourrait être de vérifier si la charge informatique installée est nettement inférieure à celle nominale.

1.5 Efficacité énergétique des centres de données : Travaux connexes

Les centres de données font partie des systèmes les plus complexes et ils représentent un secteur de consommation d'énergie important et en croissance et des installations à forte intensité énergétique, avec un impact considérable sur la consommation mondiale d'énergie.

En même temps, les progrès rapides de la technologie informatique permettent à l'industrie et à la société de générer plus de données que jamais, augmentant la demande de communication, de traitement et de stockage des données. De ce fait, l'efficacité énergétique est l'un des principaux objectifs.

Dans ce cadre, plusieurs travaux de recherche ont été réalisés afin d'approuver et évaluer l'efficacité énergétique des DCs. Jin et al. (2016) indiquent que l'approche directe du développement des DCs verts ou efficaces énergétiquement est de freiner leur consommation d'énergie en employant des techniques d'efficacité énergétique ou de bien gérer les pertes inutiles d'énergie par les différents sous-systèmes des DCs. Le concept fondamental est d'exploiter les technologies de gestion de l'alimentation des différents sous-systèmes des DCs.

Dans leurs recherche, Jin et al. (2016) décrivent, comme indiqué dans la figure 9 , les différents niveaux de mesures au sein d'un DC. Pour chaque niveau de mesure, on peut identifier l'énergie consommée par chaque sous-système de DC ainsi que les métriques adéquates et correspondantes.




Figure 1.5 Les niveaux de mesure de la puissance pour un centre de données
Tirée de Jin et al. (2016)

Pour chaque niveau, il existe une métrique d'efficacité bien déterminée. Dans ce contexte, Jin et al. (2016) et Kulseitova et Fong (2013) présentent une taxonomie des métriques qui résume les différentes métriques qui peuvent être utilisées.

Par exemple, les métriques de PUE et DCiE (Data Center infrastructure Efficiency) qui reflètent l'efficacité énergétique de la totalité de DC y compris l'infrastructure physique (les sous-systèmes de refroidissement et ventilation, et d'alimentation électrique) ainsi que les sous-systèmes TI. Les différentes métriques sont bien résumées dans le tableau 1.2.

Tableau 1.1 Une taxonomie des métriques de l'efficacité énergétique pour un DC
Tiré de Jin et al. (2016)

Metric	Description	Formulation
PUE	Power Usage Effectiveness	$PUE = \frac{\text{Total data center energy}}{\text{Total IT energy}}$
DCiE	Data Center Infrastructure Efficiency	$DCiE = \frac{\text{Total IT energy}}{\text{Total data center energy}}$
CUE	Carbon Usage Effectiveness	$CUE = \frac{\text{Total CO2 emissions from DC energy}}{\text{Total IT energy}}$
ITEU	IT Equipment Utilization	$ITEU = \frac{\text{Total measured energy of IT}}{\text{Total specification energy of IT}}$
DCP	Data Center Productivity	$DCP = \frac{\text{Useful energy}}{\text{Total facility power}}$
WUE	Water Usage Effectiveness	$WUE = \frac{\text{Annual water usage}}{\text{IT equipment energy}}$

Avec ce nombre de métrique, il faut bien évidemment définir les critères à respecter pour une bonne évaluation. De ce fait, Wang et Khan (2013) indiquent que le développement des métriques de performance du DC doit répondre aux critères suivants :

- les métriques devraient être adaptables aux différents types de DCs, y compris les DCs internes et les DCs externes, les DCs multi-niveaux et les DCs à redondances;

- évaluation du système holistique et équilibrée : une mesure de performance devrait évaluer l'ensemble du système de DC, tout en prenant en considération les différents sous-systèmes d'un DC;
- évaluation complète : les mesures de performance devraient être capables de capturer le comportement d'un DC dans différentes situations (c.-à-d. - à des charges de travail et à des modes de fonctionnement typiques);
- faible coût d'implémentation : une mise en œuvre complexe et coûteuse des paramètres de performance peut limiter sa large adoption;
- facilité d'utilisation : les gestionnaires des DCs seraient heureux de s'adapter à certaines mesures, faciles à utiliser et intuitives à comprendre.

Les DCs comme environnement complexe impliquent plusieurs unités fonctionnelles dont la consommation est liée au niveau de services. La mesure et l'amélioration de l'efficacité énergétique du DC nécessitent différents indicateurs afin d'évaluer l'impact des actions à mettre en place. Ainsi, Jin et al. (2016) indiquent que chaque niveau hiérarchique des DCs possède une métrique différente permettant d'évaluer l'efficacité énergétique par niveau et par zone de DC. La figure 1.6 ci-dessous résume les différentes métriques par niveau pour les DCs.




Figure 1.6 Les différentes métriques selon le niveau hiérarchique de DC
Tirée de Jin et al. (2016)

1.5.1 Modèles et techniques de prédiction de la température

Les DCs contiennent sous-systèmes TI hébergés dans des racks qui sont disposés en rangées. La chaleur générée par les équipements électriques est refroidie par les CRAC situés à proximité de la périphérie du DC. Ces sous-systèmes CRAC permettent à l'air froid de circuler à travers les sous-planchers.

La génération de chaleur à l'intérieur des racks change avec le temps en fonction de la quantité de charge de travail mise sur les serveurs. Le CRAC dispose d'un mécanisme permettant de modifier dynamiquement la quantité de refroidissement en fonction de la modification des conditions de charge thermique dans le centre de données. Il peut y avoir des cas d'urgence de défaillance du CRAC entraînant un dépassement des températures dans certaines régions du centre de données.

De cette façon, de nombreux paramètres du centre de données tels que les températures aux entrées des racks, la production de chaleur par les équipements dans les racks et la quantité de refroidissement fournie par CRAC sont très dynamiques. Compte tenu de ces conditions dynamiques dans le centre de données, une surveillance continue avec des alarmes et des notifications permet aux gestionnaires de centres de données de surveiller efficacement le centre de données. Michalak et al. (2018).

La surveillance continue de l'environnement dynamique dans le DC nécessite une détection continue de la température à différents endroits tels que les entrées et les sorties des racks, ainsi que la détection de la température à l'alimentation et aux retours du CRAC, etc. Mais en réalité, les DCs généralement ne sont pas équipés d'un nombre suffisant de capteurs pour caractériser au complet le profil de température des DCs.

En outre, Bhagwat, Singh, Jayaprakash, et Sivasubramaniam (2016) mentionnent que les capteurs placés ne se trouvent pas dans des endroits importants, comme les points chauds où il faut avoir plus de données collectées. Il est difficile et coûteux de mettre suffisamment de capteurs dans les DCs existants. D'où le problème de prédiction de l'énergie thermique des DCs est un défi.

Pour résoudre tous les problèmes ci-dessus, Bhagwat et al. (2016) et Michalak et al. (2018) utilisent un modèle thermique pour prédire les températures à différents endroits du centre de données en utilisant des températures mesurées à quelques endroits dans le centre de données et une consommation d'énergie mesurée des racks.

Michalak et al. (2018) indiquent que la consommation d'énergie des racks est mesurée à l'aide d'iPDU (intelligent rack PDU) qui mesurent la consommation d'énergie des appareils connectés à leurs points de sortie. La consommation d'énergie peut également être mesurée tout en exploitant Lights On Management (LOM), qui est une technologie intégrée aux serveurs qui inclut la gestion à distance des serveurs, y compris la mise hors tension ou la mise sous tension. Une architecture LOM typique, a un processeur de gestion distinct avec son

propre logiciel système et son interface réseau. Les installations LOM actuelles mesurent la consommation d'énergie des serveurs qu'ils contrôlent.

Également, Michalak et al. (2018) mentionnent que la puissance de consommation des serveurs dans les racks peut être prédite en utilisant un modèle d'estimation aussi, où une estimation empirique est effectuée en faisant recours à l'utilisation de CPU qui peut être mesurée à l'aide d'un logiciel. Cette consommation d'énergie mesurée des racks et la mesure des températures est ensuite affichée au gestionnaire du centre de données via l'interface utilisateur.

La solution proposée par Bhagwat et al. (2016) indique que les températures à différents endroits sont prédites en utilisant un modèle thermique et des mesures des températures effectuées à des endroits difficiles. En effet, les températures aux sorties des racks sont prédites à partir des températures aux entrées des racks. Dans un autre contexte, Bowling (2014) présente une autre technique de prédiction des températures au sein d'un centre de données. En effet, il se base sur les simulations de mécanique des fluides numérique (CFD : Computational Fluid Dynamics). En outre, Bowling (2014) mentionne que cette technique CFD prend trop de temps pour faire la conception de tels systèmes de centre de données hautement linéaires, dynamiques et complexes.

Un modèle à base de réseaux de neurones artificiels pour une configuration à l'échelle classique (c.-à-d. de taille moyenne) d'un centre de données est mis en place, à travers lequel la température à divers points et divers d'état peut être prédite à travers le DC. Ceci est en fonction des vitesses du ventilateur CRAC et de la chaleur dissipatrice de ces points à un instant donné. Un ensemble de données est utilisé pour l'entraînement de modèle de réseau de neurone (RN) proposé. En effet, les données sont générées par des simulations CFD grâce à des dispositions théoriques d'un DC en vraie grandeur et sous des véritables aspects. De plus, une comparaison est effectuée entre la sortie du modèle CFD et les données générées afin que la précision du RN puisse être valide. La généralisation et la validation du modèle de RN a été illustrée par le changement de la chaleur du serveur et de la vitesse du ventilateur CRAC.

Le travail effectué par Bhagwat et al. (2016) sera une bonne inspiration pour notre recherche par la suite. Tout en intégrant la relation entre la température des racks et la consommation des racks pour calculer les valeurs de PUE.

Yuya Tarutani et al. (2015) ont appliqué la technique d'apprentissage machine en utilisant des modèles de régression pour prédire la distribution de température du centre de données du cloud. La consommation d'énergie est ensuite réduite via un contrôle proactif de la charge du serveur et le réglage des paramètres CRAC. Les entrées du modèle sont la consommation d'énergie des serveurs, la température de l'air d'admission du serveur, la consommation d'énergie de l'onduleur, la distribution de la température actuelle et ses changements temporels, la température de l'air de sortie du CRAC et le volume d'air du CRAC.

Une technique de compression des données utilisant l'analyse en composantes principales (ACP) est appliquée en plus du modèle de régression. Puisqu'il existe des corrélations entre les variables d'entrée, l'ACP fait la compression essentiellement des données. Pour approuver la validité de leur modèle de prédiction, Yuya Tarutani et al. (2015) ont comparé le modèle de prédiction avec la méthode forêt d'arbres décisionnels qui utilise l'arbre de décision comme une méthode pour éviter le sur-apprentissage (overfitting) et pour augmenter la précision et la vitesse de la prédiction. Selon les résultats obtenus, Yuya Tarutani et al. (2015) montrent que le nombre de paramètres sélectionnés affecte la précision de la prédiction de la méthode de régression linéaire et de la méthode de forêt d'arbres décisionnels. À mesure que le nombre de capteurs dans le centre de données augmente, ce qui est inévitable, la sélection des fonctionnalités pour réduire le nombre d'entrées deviendrait un défi.

Pour le sujet d'exploitation des localisations à basse température, Cho et Kim (2016) proposent des méthodes d'approche analytique pour l'optimisation de l'efficacité énergétique des DCs à haute densité pour 4 régions climatiques différentes. L'objectif est de trouver une stratégie de conception adaptative qui optimisera la performance énergétique en ajustant les conditions environnementales et les applications de refroidissement.

Avec plus de détails, la solution proposée est appelée DCeET (outil d'évaluation de la performance énergétique du centre de données) qui vise à analyser efficacement l'application du système de refroidissement pour concevoir des DCs efficace énergétiquement début de la conception. Ensuite, un modèle d'énergie dynamique utilisant le DCeET a été développé pour estimer la consommation électrique. De plus, la simulation d'énergie est basée sur l'approche composante par composante, ce qui signifie que l'utilisation de la puissance de chaque composant du DC est liée à son utilisation. La validation de la solution proposée est effectuée par un prototype qui est dérivé pour chaque zone climatique.

Cette solution proposée est validée en utilisant des données réelles et des scénarios réels. Où un grand centre de données de 20 MW a été considéré pour exécuter la solution et le scénario proposé. Ainsi, de nombreuses techniques de systèmes de refroidissement sont utilisées pour évaluer l'impact de chaque technologie (tels que les systèmes de distribution d'air et les systèmes d'installation de refroidissement). En outre, une zone climatique de référence (Corée) est utilisée pour la comparaison avec quatre autres régions (Séoul / Corée, Singapour, Abu Dhabi/ Émirats arabes unis, Mongolie) en fonction de l'optimisation du système de refroidissement du DC. Basé sur l'approche analytique, les demandes d'énergie montrent une variété de modèles par différentes zones. Par exemple, dans le cas d'une zone chaude et humide, la température extérieure est élevée et les économiseurs côté air et côté eau, ne sont pas disponibles. Ce qui n'est pas le cas pour les régions froides.

le travail de Cho et Kim (2016) a une relation indirecte avec notre travail. En effet, la mesure de l'efficacité de l'utilisation de l'énergie (PUE) en tant qu'indicateur d'efficacité du centre de données est fonction de la température et de la charge de travail informatique. De plus, (Cho & Kim, 2016) mentionnent que la meilleure performance énergétique dans les centres de données est considérée comme un PUE de 1,07. Tous ces centres de données ont comme priorité absolue les conditions environnementales, telles que la température et l'humidité de la salle des serveurs informatiques. De plus, les systèmes qui utilisent un système d'économiseur côté air ou côté eau pour le refroidissement des serveurs informatiques sont activement adoptés pour réduire l'énergie.

1.5.2 Les méthodes d'optimisation des systèmes de refroidissement

Dans le même contexte et selon Cho et Kim (2016), 50% de l'énergie totale du DC est consommée par l'équipement non informatique (Non TI) (comme les sous-systèmes de refroidissement et les sous-systèmes de distribution d'énergie électrique).

L'une des principales sources d'utilisation de l'énergie dans le DC est le refroidissement, d'où le facteur dominant est les installations de refroidissement mécanique (qui représentent 33% de la consommation totale d'énergie de l'installation du DC). Cho et Kim (2016). Tout comme les ordinateurs portables génèrent beaucoup de chaleur, les DCs qui contiennent des milliers de serveurs - génèrent également beaucoup de chaleurs qui doivent être éliminées afin de garantir la performance de l'équipement informatique. Un autre problème est lié à la densité du serveur. En effet, les exigences de densité de puissance dans les DCs augmentent, de sorte que le besoin de refroidissement devient de plus en plus important. Et en même temps, une grande quantité de chaleur générée doit être retirée.

Également, il est rapporté que les coûts de refroidissement peuvent atteindre jusqu'à 50% du coût énergétique total dans un centre de données. Par conséquent, les mesures thermiques sont très importantes pour l'exploitation d'un centre de données avec une bonne efficacité énergétique.

Wang et Khan (2013) indiquent que le refroidissement prend un tiers de la consommation d'énergie totale du centre de données. Pour réduire la consommation d'énergie pour le refroidissement, Wang et Khan (2013) indiquent l'importance d'utiliser le refroidissement naturels et de l'utilisation d'énergie renouvelable. Également, Hammond (2017) mentionne que Facebook a construit son premier DC renouvelables en 2014. Son DC était construit près du cercle arctique, de sorte que le refroidissement est fourni en exploitant la température extérieure.

Le problème d'optimisation du contrôle du système de refroidissement a été examiné sous différents aspects. Beaucoup de ces littératures Jiang, Jing, Li, Wu, et Tang (2014), Jing, Jiang, Wu, Tang, et Hua (2014) et Fouladi, Wemhoff, Silva-Llanca, Abbasi, et Ortega (2017) se concentrent sur l'utilisation d'une procédure d'optimisation en deux étapes pour optimiser l'efficacité de refroidissement. Par exemple, dans la première étape, un modèle dynamique à base de l'énergie thermique est construit pour évaluer l'efficacité, comme dans le travail de recherche de Fouladi et al. (2017). Récemment dans le travail de recherche de Singh et al. (2018), les auteurs ont proposé d'utiliser un modèle de mécanique des fluides numérique (CFD) pour analyser l'efficacité du flux d'air. Ces modèles peuvent être très complexes, pour cette raison, Fouladi et al. (2017) ont proposé un modèle mathématique pour un système de refroidissement spécifique comprenant 43 équations. Avec une telle complexité, ce type de modèle est difficile à extrapoler à un autre DC avec une configuration distincte.

Pour cela, la recherche a tenté de construire une approche basée sur les données, comme les modèles basés sur l'apprentissage machine.

Restant dans le même contexte de refroidissement, Y. Tarutani et al. (2016) présentent une solution basée sur l'apprentissage par machine afin de prédire la température ainsi que la distribution efficace de l'air de refroidissement, dont le but est de minimiser la consommation énergétique. Comme procédure de travail, Y. Tarutani et al. (2016) indiquent que les données, y compris la température de sortie de l'air et le volume des systèmes de refroidissement, la consommation d'énergie des serveurs et les valeurs des capteurs, sont observées par les capteurs et les paramètres opérationnels lors de l'utilisation du centre de données cible.

D'une part, pour la prédiction de la température, les modèles de régression sont construits par régression linéaire pour prédire à l'avenir la distribution de la température à plusieurs minutes. D'autre part, les modèles de machine à vecteur de support (SVM) sont construits pour prédire l'efficacité énergétique des systèmes de refroidissement.

Donc, nous pouvons inspirer du travail de (Cho & Kim, 2016) lors de la définition des « testbeds » pour le calcul de PUE, nous pouvons considérer la contrainte d'emplacement du centre de données. En outre, nous pouvons définir un autre cas d'utilisation dans lequel nous fixons le type de technologies et de techniques de refroidissement utilisées.

En plus d'optimiser directement le système de refroidissement étudié ci-dessus, il existe un ensemble de travaux qui se concentrent sur le côté informatique du DC pour économiser l'énergie de refroidissement. Par exemple, dans le travail de Li, Zheng, Wang, et Wang (2014), le problème de répartition de la charge de travail a été étudié pour optimiser la carte thermique dans le DC afin d'améliorer l'efficacité du refroidissement. Dans le travail de recherche de Zheng, Zheng, Li, et Wang (2017), les auteurs ont proposé une nouvelle méthode de gestion des flux réseau pour utiliser moins de commutateurs afin d'économiser de l'énergie.

1.5.3 Optimisation et prédiction des métriques d'efficacité énergétique

La modélisation prédictive peut être décrite comme le processus de création, d'évaluation et de validation d'un modèle afin de prédire au mieux la probabilité d'un résultat. Pour cette modélisation, les solutions d'analyse prédictive utilisent de nombreuses méthodes de telles que les modélisation statistiques, l'intelligence artificielle et l'apprentissage automatique. La théorie de la détection est utilisée pour tester, valider et évaluer le modèle afin que la probabilité d'un résultat dans une quantité spécifique de données d'entrée puisse être prédite et que le meilleur modèle puisse être sélectionné.

Les techniques de planification et optimisation proactives utilisent des prédictions pour déterminer les données futures, ce qui permet de préparer et de déclencher l'adaptation à l'avance. La précision de ces techniques s'appuie sur le module de prédiction. Une sous-estimation ou une surestimation des valeurs prédites peut conduire à de mauvais résultats.

Il est devenu plus qu'important maintenant de travailler avec les technologies d'optimisation appropriées pour les centres de données, car les technologies de données et de cloud à croissance rapide ouvrent la voie dans diverses catégories technologiques. Une amélioration peut être observée dans n'importe quelle quantité de gain d'énergie. Dans les dernières années, les techniques d'apprentissage automatique ont été utilisées par Google et Microsoft pour l'optimisation énergétique.

Il existe plusieurs techniques de prédiction dans la littérature, mais les plus utilisées sont les séries temporelles ² Hoyer et al. (2011) et la technique de régression linéaire qui est présentée par Farahnakian, Liljeberg, et Plosila (2014) pour la consolidation des machines virtuelles dans un centre de données infonuagique. D'autres méthodes de prédiction sont basées sur l'apprentissage par machine.

Des travaux de recherche ont été effectués en utilisant des techniques d'apprentissage machine. En outre, Google et à travers de travail de Gao et Jamidar (2014) utilise l'algorithme de réseaux de neurones artificiels (ANN) pour prédire les valeurs de PUE. Ainsi que la méthode des k plus proches voisins (KNN) présente par Farahnakian, Pahikkala, Liljeberg, et Plosila (2013) pour prédire l'utilisation des ressources du serveur.

De plus, les techniques de prévision sont utilisées à différents niveaux dans le DC, au niveau de la consommation des ressources tel que la prédiction de l'utilisation de la CPU Farahnakian et al. (2014), au niveau d'application de l'utilisation de VM Farahnakian et al. (2014) et de la consommation globale d'énergie DC Gao et Jamidar, 2014).

Dans ce qui suit de cette partie, on va s'intéresser sur les techniques de prédictions qui peuvent être utilisés afin de déterminer les valeurs de PUE ainsi que les paramètres clé qui font partie de PUE (ex : refroidissement, etc.).

² Série chronologique est un ensemble d'observations, chacune étant enregistrée à un moment précis généralement pour comprendre son évolution passée et pour en prévoir le comportement futur. Hamilton (1994)

Comme c'est indiqué dans la section 2.3.1, la définition de PUE prend en considération l'énergie totale consommée par le DC ainsi que l'énergie consommée par les équipements informatique (TI). Afin de calculer le PUE, Sheehan (2013) présente différentes hypothèses, en adoptant les standards donnés par *Green Grid* et *Uptime Institute* Stansberry (2017) qui déterminent les valeurs de PUE par niveaux de mesure. Pour donner suite à cette définition, les résultats de calcul de PUE selon les différents niveaux sont présentés dans la figure ci-dessous :




Figure 1.7 Les valeurs de PUE par niveaux de mesure selon Uptime Institute
Tirée de Stansberry (2017)

Afin de prouver l'importance des systèmes de refroidissement dans le calcul de PUE, Sheehan (2013) admet une hypothèse indiquant que les pertes des sous-systèmes UPS peuvent être ignorées dans les calculs PUE. En effet, dans le but d'illustrer l'efficacité du sous-système de refroidissement, les valeurs PUE sont souvent calculées à l'exclusion des pertes de UPS. En plus, Sheehan (2013) prouve que les valeurs PUE qu'il le nomme « PUE mécaniques » résultantes ne comprennent que deux composants énergétiques; l'énergie essentielle de charge informatique et l'énergie de refroidissement du DC (avec l'espoir d'inclure les systèmes centraux et l'énergie locale des ventilateurs).

Comme pour les valeurs partielles PUE, il n'y a aucune reconnaissance industrielle des valeurs PUE mécaniques. Selon son travail, les pertes de UPS avec l'hypothèse (H2) ne représentaient qu'environ 4% de la puissance totale. Cependant, comme illustré dans la figure ci-dessous, ignorer ces pertes de UPS (avec l'énergie des systèmes auxiliaires) a entraîné des valeurs PUE mécaniques reflétant une amélioration de 0,09 à 0,10 par rapport aux valeurs PUE réelles.

Selon notre compréhension et nos recherches effectuées sur cette problématique, l'élimination des pertes des sous-systèmes de UPS et PDU afin d'arriver à alimenter les systèmes TI, ne reflète pas une valeur exacte de PUE.

C'était bien important d'avoir des valeurs optimales de PUE (cad proche de 1.0) mais à la fois nous avons besoin des valeurs exactes qui reflète la réalité énergétique des DCs pour que nous puissions prendre les bonnes décisions par la suite.

Également, même lorsque les PUE sont calculés en stricte conformité avec les normes de l'industrie « Uptime Institute », PUE ne peut pas prédire avec précision les performances énergétiques. Cela s'explique principalement par des variations généralement volatiles dans le chargement des systèmes informatiques critiques. Au fur et à mesure que la charge critique est en dessous de sa consommation, plusieurs sous-systèmes y compris l'énergie totale de l'installation du centre de données restent relativement constants. Il en résulte une augmentation des valeurs PUE dans toutes les catégories. Ce problème de complexité et de non-linéarité de système énergétique crée un défi pour les chercheurs afin de trouver des solutions automatiques et intelligente.

Dans ce contexte, Vishal Kumar (2016) indiquent que chaque petite quantité de gains d'efficacité énergétique est une amélioration, d'où plusieurs grandes entreprises telles que Microsoft et Google travaillent sur ce problème en essayant chaque fois d'être à jour et en appliquant des nouvelles techniques. En effet, Vishal Kumar (2016) mentionne que Microsoft et Google ont utilisé des techniques d'apprentissage par machine pour l'optimisation de l'énergie.

Microsoft mesure les piques de charge de travail du serveur et automatise les opérations du DC. Alors que Google avec la recherche réalisée par Gao et Jamidar (2014) explorent l'utilisation de techniques d'apprentissage par machine pour optimiser le DC à travers l'optimisation de l'utilisation d'énergie au niveau du bâtiment. En plus, Vishal Kumar (2016) mentionne qu'il n'y a pas eu d'application de techniques d'apprentissage machine dans des DCs de taille moyenne. Ceci est dû au manque de machines d'instrumentation et à la mise en œuvre de la plate-forme Internet des objets (IdO) pour collecter et stocker suffisamment des données. L'apprentissage par machine peut être modélisé avec précision pour représenter les caractéristiques réelles d'un DC. Toutes les études connexes pour les DCs de taille moyenne utilisent des simulations nous montrons des résultats, tout en collectant des données à partir d'opérations pratiques dans un DC de taille moyenne.

En effet, l'étude proposée par Vishal Kumar (2016) considère des micro-systèmes comme les DCs modulaires dans les installations multi-locataires avec des serveurs hétérogènes, voir la figure 1.8. Cette étude vise à optimiser davantage l'environnement des micro-installations liées à une suite de données pour une charge de serveur donnée.




Figure 1.8 Exemple d'un centre de données hétérogène
Tirée de Vishal Kumar (2016)

Comme les DC modernes à grande échelle disposent d'une grande variété d'équipements mécaniques et électriques, ainsi que de leurs points de consigne et de leurs systèmes de contrôle associés.

Les interactions entre ces systèmes et les différentes boucles de rétroaction rendent difficile la prédiction précise de l'efficacité du DC en utilisant des formules d'ingénierie traditionnelles (les modèles d'optimisation standard). Vishal Kumar (2016) utilise le réseau de neurone (RN) pour produire un ensemble optimal de paramètres. Les unités linéaires rectifiées (ReLU) sont utilisées pour l'apprentissage en profondeur. Le modèle est formé pour donner une valeur optimale de PUE. Dans le même contexte, Pegus II et al. (2016) indiquent les paramètres qui influencent la variation de PUE. Ils analysent plus en détail les principaux contributeurs au PUE et parmi ces contributeurs, les sous-systèmes de refroidissements. En effet, l'infrastructure de refroidissement du DC est dimensionnée pour une charge beaucoup plus grande d'où le problème des grandes valeurs de PUE. La figure 1.9 ci-dessous illustre bien les éléments clé qui influencent la variation de PUE.




Figure 1.9 Les facteurs qui contribuent au PUE
Tirée de Pegus II et al. (2016)

Également, Gao et Jamidar (2014) proposent une solution basée sur l'apprentissage par machine. En effet, le réseau de neurones (RN) est choisi comme un Framework mathématique pour l'apprentissage de modèles d'efficacité énergétique des centres de données. Cette solution a comme objectif de démontrer une approche basée sur les données pour optimiser les performances du DC en fonction de PUE. Tout en maximisant l'efficacité de DC et tout en maintenant un environnement stable.




Figure 1.10 Algorithme de réseau de neurone à trois couches
Tirée de Foo, Goh, Lim, et Li (2015)

Tout d'abord, ils ont défini les réseaux de neurones comme présenté dans la figure 1.10. En effet, les réseaux neuronaux sont une classe des algorithmes d'apprentissage par machine qui imitent les comportements cognitifs via les interactions entre les neurones artificiels.

Ils sont avantageux pour la modélisation de systèmes complexes car les réseaux de neurones n'exigent pas que l'utilisateur prédéfinisse les interactions de paramètres d'entrée dans le modèle. Ainsi, le réseau de neurone recherche des modèles et des interactions entre les fonctionnalités pour générer automatiquement un modèle adapté.

La question qui se pose à ce niveau, c’est pourquoi utilisée l’algorithme de réseau de neurones. Tout d’abord et d’une façon générale, il est utilisé parce qu’il est capable d’analyser les modèles en ligne (ceux qui changent avec le temps). Généralement, il s’agit des données variables dans le temps qui doivent être adaptés et prédits Foo et al. (2015).

Et dans le contexte de la solution proposée par Gao et Jamidar (2014), l’algorithme de réseau de neurone est utilisé parce qu’il suit les étapes suivantes:

- prendre un nombre de données;
- trouver les interactions cachées;
- fournir des recommandations qui optimisent l’efficacité énergétique.




Figure 1.11 Exemple de réseau de neurone pour calculer PUE

La formulation mathématique pour la solution proposée est donnée comme suit :

x : matrice d’entrée ($m \times n$)
m : nombre des exemples d’apprentissage (training examples)
n : nombre des “features” (les variables d’entrée des centres de données Y compris la charge TI, les conditions météorologiques, le nombre de refroidisseurs, etc.)

En effet, la matrice d'entrée x est multipliée par paramètres θ_1 pour obtenir une matrice d'état cachée a . Dans ce cas, la matrice a agit comme un état intermédiaire qui interagit avec le deuxième paramètre θ_2 pour calculer la sortie $h(x)$ (qui est la fonction hypothèse). La figure 1.11 présente le réseau de neurone extraite de l'article de Gao et Jamidar (2014).

A titre de remarque, la taille et le nombre de couches cachées peuvent varier pour modéliser des systèmes avec une complexité variable.




Figure 1.12 Exemple de réseau de neurone
Tirée de Gao (2014)

Le réseau de neurone proposée par (Gao et Jamidar (2014) cherchera des relations entre les fonctions de données pour générer un modèle mathématique qui décrit $h_{\theta}(x)$ en fonction des valeurs d'entrée. Également, l'algorithme de neurone proposée vise à utiliser les modèles pour donner de nouvelles façons pour obtenir plus d'efficacités hors exploitation. Par exemple, certains serveurs sont déconnectés pendant quelques jours, ce qui rendrait normalement ce centre de données moins efficace sur le plan énergétique. En utilisant le modèle proposé qui modifie la configuration de refroidissement temporairement - en réduisant l'impact de la modification sur la PUE pour cette période.

Le processus d'apprentissage d'un modèle de réseau neuronal peut être divisé en quatre étapes :

- initialiser de manière aléatoire les paramètres du modèle θ $([-1,1])$;
- implémenter l'algorithme « forward propagation »;
- calculer la fonction de coût $J(\theta)$;
- mettre en œuvre l'algorithme de Rétro-propagation (Backpropagation algorithm) ;
- répétez les étapes 2 à 4 jusqu'à arriver à la convergence ou le nombre d'itérations désiré;

L'implémentation de cet algorithme utilise les données suivantes :

- 5 Couches cachées,
- 50 nœuds par couche cachée,
- la valeur 0,001 est utilisé comme un paramètre de régularisation (qui contrôle le compromis entre la précision du modèle et l'ajustement excessif),
- l'ensemble de données d'apprentissage contient 19 variables d'entrée,
- une variable de sortie : la valeur de PUE de centre de données.

Le modèle de MLP (MultiLayer Perceptron) proposé par Gao et Jamidar (2014) a atteint une précision prédictive élevée avec une erreur absolue moyenne de 0,004 et un écart-type de 0,005 sur l'ensemble de données de test.

Dans le même contexte de l'efficacité énergétique pour les DCs, Foo et al. (2015) présentent une solution basée sur le réseau de neurone (NN) et l'algorithme génétique (AG). Cette solution vise à résoudre quelques lacunes présentées dans la solution proposée par Gao et Jamidar (2014). En effet, Gao et Jamidar (2014) utilisent comme précédemment décrit le réseau de neurone pour calculer la bonne valeur de PUE. Traditionnellement, les réseaux de neurones Hibat-Allah Ounifi (2015) utilisent une méthode appelée «*back-propagation*», basée sur une fonction qui varie en fonction de la variation de ses différents paramètres pour optimiser les poids du réseau avec une architecture fixe et pour produire l'erreur de modélisation la plus basse.

Bien que cette approche soit efficace, la « back-propagation » entraîne souvent la saisie de la recherche dans un minimum local. En outre, en raison d'un nombre fixe de neurones et de connexions, Cette approche n'est pas adaptée à la modélisation des systèmes non-linéaires, Où plusieurs minimas locaux existent souvent. De plus, Dans un centre de données, de multiples systèmes électriques et mécaniques interagissent tout en fournissant de l'énergie et du refroidissement aux serveurs physiques consolidés dans un environnement virtuel de cloud. Par conséquent, les caractéristiques de consommation d'énergie des centres de données en nuage présentent une non-linéarité.

Afin de résoudre le problème de la non-linéarité de fonction de l'efficacité énergétique, Foo et al. (2015) propose un algorithme de recherche global tel que l'algorithme génétique (GA) qui surmonte cette difficulté, mais souffre d'une faible convergence car il s'agit d'un algorithme polynomial indéterminé (NP). Donc, un nouveau mécanisme de mise en œuvre et d'implémentation de le GA est proposé pour améliorer le taux de convergence pour la modélisation de RN. Un nouveau schéma de codage représente les pondérations et la structure de réseau de neurone dans une représentation matricielle dont le but est d'améliorer l'efficacité des opérations d'algorithme GA pour la recherche de RN.

Pour valider le modèle évolutif de RN, Foo et al. (2015) ont mis en place un «Hadoop cluster»³ pour les expériences. Les ensembles de données sont collectés du « Hadoop cluster ». Les entrées de l'algorithme RN représentent des caractéristiques liées à l'énergie et la sortie représente la consommation d'énergie du cluster.

³ Un « Hadoop cluster » est un type spécial de cluster informatique spécialement conçu pour stocker et analyser d'énormes quantités de données non-structurées dans un environnement informatique distribué.

Alors que la valeur de sortie de l'algorithme de RN est la consommation d'énergie mesurée en kilowattheure. Les caractéristiques ainsi que la méthode de collecte, sont décrites dans le tableau 1.2 ci-dessous.

Tableau 1.2 Le paramètre de sortie pour la consommation d'énergie
Tiré de Foo et al. (2015)

Catégorie	Métrique	Unité	Description	Méthode de collection
Energie	Consommation d'énergie	KWh	Energie consommée par le cluster Hadoop	Récupération de SNMP à partir de « Retiran iPDU »

Comme c'est déjà mentionné dans ce qui précède, que l'énergie consommée pour le refroidissement présente une grande partie et un facteur clé pour la formule de calcul de PUE.

Le calcul de PUE est basé sur l'optimisation l'énergie consommée par les sous-systèmes de refroidissement. En effet, afin de minimiser la puissance consommée pour le refroidissement, Shoukourian, Wilde, Labrenz, et Bode (2017) utilisent l'algorithme de réseau de neurone artificiel (ANN) et le modèle proposé a comme paramètres d'entrées :

- la quantité totale de froid générée par chaque circuit de refroidissement,
- la quantité totale de puissance consommée par les ventilateurs de chaque tour de refroidissement,
- le nombre de tours de refroidissement actives,
- la température,
- la température de l'eau d'entrée (à la barre de distribution) de chaque circuit de refroidissement,
- la température de retour de l'eau (à la barre de distribution) à chaque circuit de refroidissement.

Comme paramètre de sorti : le Coefficient de Performance (COP) de la boucle de refroidissement d'eau chaude.

1.5.4 Limites et contributions

Bien que plusieurs travaux de recherche ont été menés dans le but d'optimiser et de prédire l'efficacité énergétique des DCs, certaines limites limitations persistent et entraînent la non-généralisation des telles solutions pour des systèmes complexes tels que le DC. En effet, l'absence de variétés de données et des cas de tests réels limitent ces solutions. Pour notre cas, nous travaillons sur deux cas réels de DCs avec des tailles différentes et des localisations géographiques différentes afin de valider la solution proposée.

En effet, l'objectif de la modélisation est clair : développer des modèles prédictifs pour évaluer les actions des différents systèmes de la couche d'infrastructure DC sur la métrique d'efficacité énergétique PUE. Une partie des objectifs est d'utiliser ces modèles dans des analyses et des scénarios visant à évaluer les actions du DCs.

À cette fin, nous utiliserons la technique d'apprentissage intelligent profond qui apprend des données collectées de manière opérationnelle pour prédire avec précision l'efficacité énergétique (EE) et créer un modèle de contrôle pour valider les résultats des tests. Et développer un modèle qui comprend les relations entre les paramètres opérationnels et l'efficacité énergétique globale.

CHAPITRE 2

METHODOLOGIE DE RECHERCHE

2.1 Introduction

Notre recherche suit une approche itérative et incrémentale afin de répondre aux objectifs de recherche déjà mentionnés, combinée avec la méthodologie de PPCGO (Préparer- Planifier- Concevoir-Générer-Optimiser) qui est formée de trois principales itérations : la modélisation d'un métamodèle qui définit les différents sous-systèmes d'un DC, génération des modèles énergétique et identification des paramètres de définition de PUE, et prédiction de l'efficacité énergétique des DCs en utilisant la métrique de PUE.

Une partie de validation de métamodèle est traduite par une méthode de prédiction de l'efficacité énergétique des exemples réels de DCs. Tout d'abord, une définition générique et détaillée de la métrique d'efficacité énergétique sera donnée, tout en se basant sur le métamodèle pour définir les différents niveaux de mesures ainsi que les paramètres nécessaires. De ce fait, une définition précise de la métrique de PUE sera proposée, permettant de concevoir l'efficacité de l'utilisation d'énergie. Cette définition mettra l'accent sur les caractéristiques environnementales extérieures du DC, en étudiant les caractéristiques météorologiques (température extérieure, humidité, etc.). Par la suite, une mise en place des modèles de prédiction qui permettent de prédire et de déterminer les valeurs optimales de PUE et les comparer avec les valeurs réelles.

Notre méthodologie de recherche va être détaillée dans les sections qui se suivent.

2.2 M1- métamodèle : Modélisation de Centre de Données

Dans l'ingénierie dirigée par les modèles, ces derniers ne sont pas seulement utilisés pour documenter la conception d'un système, mais également pour effectuer des analyses, générer des modèles plus spécifiques, créer des instances ou exécuter des simulations. Pour prendre en charge de telles transformations, les instances de modèle individuelles doivent se conformer à un métamodèle qui est exprimé à l'aide d'un langage de modélisation. Toutes les transformations vers d'autres modèles dépendent directement de ce métamodèle.

En plus, les métamodèles peuvent être utilisés pour comprendre le système physique, optimiser sa conception, et effectuer des vérifications et des validations.

En se basant sur ces notions, nous proposons un métamodèle de centre de données (DCMM : Data Center MetaModel) en détaillant les sous-systèmes, leurs interactions ainsi que leurs interdépendances. Pour la modélisation, nous avons utilisé deux standards : OMG UML (Object Management Group) pour les notations graphiques de la modélisation et le langage OCL (Object Constraint Language) pour définir les contraintes.

Cette première partie de notre méthodologie (M1) est basée sur les trois phases de méthodologie de recherche choisie PPCGO qui sont : la phase de préparation, planification et conception. Dans ce qui suit, nous allons détailler le métamodèle proposé.

Nous adoptons ces étapes (Figure 2.1) pour définir le métamodèle DCMM.




Figure 2.1 Approche proposée de définition du métamodèle

2.2.1 Aperçu générale de métamodèle

Les étapes de conception du DC impliquent généralement les compétences des architectes, des ingénieurs en mécaniques, électriques, informatique, système et réseau, des chefs de projet et du personnel d'approvisionnement. Pour cette fin, un modèle de référence est nécessaire afin d'avoir un aperçu générique des DCs. En effet, un métamodèle holistique de centre de données (DCMM) est proposé détaillant l'infrastructure de base d'un DC.

En outre, le métamodèle en tant que modèle basé-UML (spécifiquement des diagrammes de classe) présente les relations entre les différents sous-systèmes pour le même espace ainsi que la relation entre les espaces eux même.

Le DCMM présente tous les niveaux formant l'infrastructure de base d'un DC. Il est important de déterminer les sous-systèmes et leurs interactions à partir de la sous-station de service externe via la distribution du bâtiment hébergeant le DC vers les racks individuels, et enfin jusqu'aux charges informatiques de bas niveau. Chaque niveau de cette hiérarchie apporte ses propres défis.

En plus, le métamodèle met l'accent sur les niveaux individuels et les défis que chacun implique. Par exemple lorsque l'administrateur de DC installe un sous-système de n'importe quel niveau, il a l'avantage de savoir à l'avance où il va placer le sous-système et les autres sous-systèmes qui sont en lien avec.

Notamment, on admet que le métamodèle est formé par 4 sous-modèles :

- modèle qui représente l'espace mécanique,
- modèle qui représente l'espace électrique,
- modèle qui représente l'espace informatique (TI),
- modèle qui représente l'espace de control.

Les systèmes formant l'espace électrique présentent une partie des sous-systèmes énergétique de DC et qui présente la partie de base pour l'alimentation de la totalité de DC. À partir de la source d'alimentation électrique, l'alimentation passe généralement par des transformateurs de tension, des commutateurs de transfert statiques ou automatiques (Static Transfert Switch STS ou Automatic Transfert Switch ATS), des sous-systèmes d'alimentations sans interruption (UPS), des unités de distribution d'alimentation (PDU) et enfin des systèmes d'alimentation des racks.

Le système UPS fournit une batterie de secours en cas de courtes coupures d'alimentation. D'autres sources d'énergie locales (par exemple des générateurs diesel) sont habituellement utilisées pour des interruptions plus longues.

Ensuite, nous retrouvons les systèmes mécaniques qui contiennent les sous-systèmes de refroidissement. Les principaux sous-systèmes d'infrastructure de refroidissement sont les unités de climatisation des salles informatiques (Computer Room Air Conditioning : CRAC), les refroidisseurs et les tours de refroidissement. Ces sous-systèmes représentent une grande partie de la consommation d'énergie des DCs.

Également, les sous-systèmes pour l'espace informatique (TI) sont composés de périphériques réseau, de stockage et de serveur. L'équipement réseau comprend le matériel physique qui transmet des données, telles que les concentrateurs de réseau, les commutateurs et les routeurs.

Finalement, l'espace de contrôle présente les systèmes de surveillance afin de surveiller les différents sous-systèmes de DC en temps réel et garder la haute disponibilité des DCs.

2.2.2 Modélisation de l'espace électrique

Cet espace contient tous les sous-systèmes électriques d'un DC, y compris une puissance d'entrée qui fournit de l'alimentation électrique à l'ensemble du DC. La puissance d'entrée peut être une source énergie électrique ou une source d'énergie alternative (énergie hydroélectrique, éolienne, géothermique et solaire, etc.). La disponibilité de ce type d'énergie dépend de la localisation de DC.

La puissance d'entrée est généralement à haute tension, on a besoin d'un transformateur d'entrée pour transformer le courant alternatif de haute tension en courant alternatif de moyenne ou basse tension. Le sous-système de transformation de courant en entrée ***Input_transformer*** utilise un appareillage pour gérer le sous-système d'alimentation d'entrée ***input_power*** en le mettant en mode allumé ou éteint. De ce fait, l'espace électrique indique que tout DC dispose de deux sources d'alimentation indépendantes. D'abord l'alimentation électrique (présentée par la classe **Utility_power**) et la deuxième alimentation de secours fournie par les générateurs (présentée par la classe **generator**).

L'alimentation électrique dans le DC est contrôlée par ce qu'on appelle un commutateur de transfert automatique ou ATS. L'objectif principal d'un système ATS est de détourner le chemin de l'électricité d'une source à l'autre.

Ensuite, le tableau de distribution principal est directement connecté à un sous-système de commutateur de transfert ((Transfert Switch TS) qui isole le générateur de secours du service électrique lorsque le générateur est en marche et fournit une alimentation temporaire. Le commutateur de transfert peut être un commutateur de transfert statique (STS) ou un commutateur de transfert automatique. Nous parlons d'une relation d'héritage entre les classes de TS, ATS et STS.

D'une part, ces deux sous-systèmes (ATS et STS) diffèrent fondamentalement dans le mécanisme de commutation : les ATS sont des sous-systèmes électromécaniques et les STS utilisent la technologie des semi-conducteurs. D'autre part, les commutateurs ATS sont différents des commutateurs STS pour fournir une commutation de charge rapide (généralement 1/4 de cycle) Kontorinis et al. (2012), ce qui représente un équipement qui assurerait un travail ininterrompu. La reconversion de la charge en puissance d'entrée principale est en fait instantanée (selon Karpati et al. (2012) le temps de réponse est ≤ 8 ms).

Également, l'utilisation d'un appareillage électrique (*Switchgears*) et un tableau électrique (*Switchboard*) comme référence pour les équipements de distribution de disjoncteurs de classe 480 volts (ou 600 volts). Mais il existe des différences notables dans les configurations, les composants, les normes, les applications, la fiabilité et les critères de sélection entre ces deux types d'équipement de distribution d'énergie.

Un processus typique d'installation électrique commence avec l'électricité primaire (Utility power) ou générateur de secours qui alimente les systèmes UPS, qui fournissent à la fois une alimentation de secours et qui alimentent ensuite les unités de distribution en rack et enfin l'équipement informatique.

Certaines pertes se produisent dans le chemin d'alimentation, mais elles sont généralement mineures par rapport à la consommation d'énergie d'autres équipements.

2.2.3 Modélisation de l'espace mécanique

L'espace mécanique de métamodèle présente les sous-systèmes de refroidissement. Le DC contient des racks, hébergeant divers équipements électriques et les racks sont disposés en rangées. Le contrôle et la maintenance du chauffage, de la ventilation et de la climatisation (Heating, Ventilation and Air Conditioning : HVAC), ainsi que les niveaux d'humidité relative (HR), sont essentiels dans le DC.

En effet, les sous-systèmes TI présentent toujours des exigences élevées dans les conditions de travail, en particulier le contrôle de la température intérieure (22 ± 2 °C) et de l'humidité ($50 \pm 5\%$) selon l'agence de Uptime Institute Stansberry (2017). Par conséquent, le système de climatisation est d'une grande importance dans le refroidissement de l'espace pour les DCs, compte tenu des émissions de chaleur énormes et consécutives.

La chaleur générée par l'équipements électriques est refroidie par les sous-systèmes CRAC. Ces sous-systèmes CRAC permettent à l'air froid de circuler dans le plénum du sous-plancher. Cet air froid est acheminé vers les emplacements spécifiques (par exemple, les façades des racks). L'équipement a généralement des ventilateurs pour prendre l'air froid. Cet air absorbe la chaleur générée et l'air chaud est évacué. Une partie de cet air chaud est renvoyée au CRAC et une partie de cet air chaud peut se mélanger à l'air froid et être recyclée dans les entrées d'équipement. Cette recirculation de l'air chaud peut entraîner une augmentation de la température d'entrée du rack au-delà de la température recommandée par le fabricant de l'équipement. En effet, les températures et les niveaux d'humidité relative en dehors des plages de fonctionnement spécifiées, ou des oscillations extrêmes dans les conditions, peuvent entraîner des composants non fiables ou des défaillances du système.

Le refroidissement est un élément essentiel de l'infrastructure d'un DC et un certain nombre d'approches sont disponibles pour maintenir les températures nécessaires au fonctionnement de l'équipement électronique des DCs.

2.2.3.1 Conceptions des sous-systèmes de refroidissement

- **refroidissement à l'air « L'utilité de la classe CRAC de l'espace mécanique du métamodèle :**

Le refroidissement par air implique l'utilisation de climatiseurs de salle informatique (CRAC) pour convertir l'air chaud en air frais en évacuant la chaleur vers l'extérieur. Les CRAC peuvent être utilisés dans un certain nombre de configurations de base qui se concentrent sur le refroidissement de la pièce entière, juste une rangée ou juste un rack. La climatisation dans une pièce entière situe les CRAC de telle sorte qu'une certaine température est maintenue assez uniformément dans toute la pièce. Les sous-systèmes CRAC fournissent de l'air frais sous la pièce, et les ventilateurs le tirent vers le haut pour refroidir les serveurs et autres équipements. L'air chaud qui transporte la chaleur dégagée des serveurs s'élève alors et les CRAC la recueillent plus haut dans la pièce, la refroidissent et la ramènent sous le plancher pour répéter le cycle. La chaleur est ensuite transférée hors de l'installation (c.-à-d. en dehors de DC). En plus de cette classe, les concepteurs des DCs définissent des designs de DCs qui mettent en œuvre des allées chaudes et des allées froides pour isoler davantage l'air chaud de l'air frais, pour fournir encore plus d'efficacité;

- **conceptions de refroidissement par liquide « L'utilité de la classe CRAH de l'espace mécanique du métamodèle :**

Le refroidissement par liquide pose des défis techniques et budgétaires plus importants que le refroidissement par air. Une conception de refroidissement à base de liquide implique des refroidisseurs qui évacuent la chaleur vers l'extérieur, souvent avec l'aide d'une tour de refroidissement, pour fournir de l'eau froide. Ce liquide est ensuite transporté vers le DC, que ce soit directement dans les racks ou dans un système de traitement d'air (**CRAH**);

Contrairement au sous-système CRAC qui utilise la réfrigération mécanique pour refroidir l'air introduit dans DC, un CRAH utilise des ventilateurs, le refroidissement à eau pour éliminer la chaleur. Également, le refroidissement par liquide (à eau) nécessite plus d'infrastructure, en particulier les circuits qui transportent le liquide dans l'installation et éventuellement directement vers les racks;

- **refroidissement gratuit « Free Cooling » :**

En utilisant de l'air frais de l'extérieur pour refroidir l'équipement. Lorsque la température extérieure est basse, l'air frais peut être amené directement par le système de ventilation pour un refroidissement gratuit. Un tel système peut tirer le meilleur parti des potentiels de refroidissement naturel ambiant sans aucun équipement de réfrigération supplémentaire. Néanmoins, en raison du mélange d'air intérieur-extérieur, il est difficile de répondre aux exigences de qualité de l'air intérieur pour le système de refroidissement direct à l'air frais. Ainsi, un tel système de ventilation fonctionne souvent avec d'autres équipements de traitement de l'air frais, y compris un appareil de déshumidification, des filtres et des filtres à air, pour éliminer l'humidité, les poussières et autres polluants, ce qui augmentera inévitablement les coûts primaires et d'exploitation. Cette approche pose toutefois certaines difficultés, telles que la présence de variations d'humidité.

2.2.4 Modélisation de l'espace TI

Les serveurs d'un DC sont organisés en rack conventionnels ou en configurations de lames à haute densité. Cet espace présente la partie IT du centre de données. En effet, cet espace implique généralement des serveurs hébergés dans des racks ; sous-systèmes de stockage; dispositifs de mise en réseau, tels que commutateurs, routeurs et câblage; et des appareils réseau dédiés, tels que les pare-feux de réseau.

Les racks de DC sont conçus pour héberger des serveurs, des périphériques réseau, des câbles et d'autres équipements informatiques de DCs. Cette structure physique permet l'orchestration des sous-systèmes TI au sein d'un DC. En effet, la puissance maximale du rack est désignée sous le nom de puissance maximale du rack, qui est déterminée par l'attribut

Rack_Max_Power de la classe **rack**, et adopte généralement sa puissance nominale (kVA ou kW). Lorsque la puissance totale de tous les périphériques empilés dans un rack atteint ou dépasse sa puissance maximale, l'alimentation est coupée pour protéger ces périphériques. Pendant ce temps, la puissance maximale du serveur est désignée sous le nom de **Server_Max_Power**, qui adopte généralement la puissance nominale du serveur. De plus, la consommation d'énergie du serveur ne dépasse pas sa puissance maximale, même s'il fonctionne à pleine capacité. La puissance maximale du serveur est bien inférieure à sa puissance nominale.

La mesure de la consommation d'énergie des sous-systèmes TI provient des unités de distribution d'énergie à l'intérieur des racks. Les PDU des racks (rack-PDU) disposent de fonctions de contrôle intégrées pour permettre un contrôle continu de l'alimentation. Pour une plus grande compacité et fonctionnalité, les serveurs peuvent être logés dans un châssis autonome qui se glisse lui-même dans le rack. Un châssis est livré avec sa propre alimentation, ses ventilateurs, son interconnexion de fond de panier et son infrastructure de gestion. Le châssis fournit des emplacements de taille standard où l'on peut insérer des actifs modulaires (généralement appelés lames).

2.2.5 Modélisation de l'espace de control

La surveillance de l'état, de l'intégrité et de la charge du système est un outil utile pour comprendre comment chaque sous-système fonctionne, seul et en relation avec d'autres sous-systèmes connectés. En effet, cet espace de contrôle assure la surveillance des différents espaces de DC y compris les sous-systèmes (tels que des serveurs, des commutateurs réseau et des PDU en rack, ainsi que les CRAC, UPS, etc.). Ceci fournit aux gestionnaires de DC des vues beaucoup plus précises et complètes des événements du DC et leur permet de gérer efficacement de nombreux sous-systèmes, d'améliorer l'efficacité et de maintenir la disponibilité.

2.2.6 Les contraintes de métamodèle

Dans cette partie, nous présentons les contraintes à respecter lors de la modélisation et la mise en place d'un modèle de DC. Nous traduisons les contraintes citées ci-dessous avec le langage OCL. En effet, un diagramme UML, tel qu'un diagramme de classes (le cas de métamodèle DCMM), n'est pas généralement suffisant pour fournir tous les aspects pertinents d'une spécification. Il y a, entre autres, un besoin de décrire des contraintes supplémentaires dans le modèle. Les contraintes OCL peuvent être utilisées pour plusieurs objectifs. Dans notre cas, nous les utilisons pour : (1) décrire les conditions préalables et postérieures aux fonctionnements de certains sous-systèmes. (2) préciser les contraintes sur les opérations des DCs.

1. Contrainte d'électricité (CE)

- la conversion de la haute tension en moyenne ou basse tension (Input_power Voltage et la classe Input_Transformer);
- si le sous-système d'**Utility_power** est en panne, UPS == Backup (Fournir **backup_power**) et le temps ≤ 10 min. Les sous-systèmes ATS font appel aux UPS et transfère l'alimentation de sa source primaire à une source de secours;
- convertir la tension d'entrée : il devient nécessaire de fournir de l'énergie à l'aide de lignes à haute tension (par exemple, 33 KV, triphasé) et de la réduire jusqu'à la plage 220–480V (triphasee) à travers les sous-systèmes d'alimentation sans interruption (Uninterruptible power supply : UPS). Le sous-système UPS doit convertir le courant alternatif (CA) en courant continu (CC) pour charger ses batteries, puis convertir CC en CA à la sortie. La sortie de l'UPS (généralement 240/120 V, monophasé) est acheminée vers l'unité de distribution d'alimentation (PDU) qui, à son tour, alimente les serveurs individuels montés en rack. Ensuite, la puissance est réduite, convertie de CA en CC et partiellement régulée afin de produire les sorties typiques (en fonction des caractéristiques indiquées sur chaque sous-système TI) et avec les courants nominaux souhaités (en fonction des caractéristiques

indiquées pour chaque composant de sous-système, par exemple pour alimenter les cartes mères de 20–100 A).

2. Contraintes de redondance des DCs (CR)

- si la redondance de DC est de Niveau 1, donc pas de redondance;
- si la redondance de DC est de Niveau 2, il y a redondance dans l'alimentation et le refroidissement, équipement à double alimentation;
- si la redondance de DC est de Niveau 3, les équipements redondants ($N + 1$) et tous les équipements informatiques sont à double alimentation;
- si la redondance de DC est de Niveau 4, l'infrastructure entièrement redondante ($2N + 1$).

Il est important de considérer toutes les ressources possibles qui seront nécessaires pour la redondance. Les sous-systèmes redondants permettent un fonctionnement ininterrompu du DC pendant les mises à niveau et les remplacements des systèmes électriques et les systèmes de refroidissement tel que HVAC. Une nouvelle unité HVAC peut être exécutée simultanément avec le matériel qu'elle remplace plutôt qu'échanger les deux. De ce fait, la redondance assure que les contrôles de l'alimentation et de l'environnement sont disponibles en cas de panne d'alimentation ou d'équipement. A ce niveau, il y a certaines questions qui se posent : Des unités HVAC redondantes seront-elles nécessaires et, si oui, où seront-elles placées? Une plus grande capacité de câblage électrique devrait-elle être préinstallée pour les futurs systèmes ? Il est important que les intentions de redondance soient maintenues à mesure que les demandes du DC changent et augmentent.

En outre, dans notre modélisation, nous envisageons la redondance totale pour les sous-systèmes UPS et les générateurs de secours. En effet, ce choix est importants et deux fois plus importants si ces sous-systèmes sont totalement redondants, dans un DC à mission critique où le coût d'une minute d'arrêt peut même coûter des millions de dollars.

3. Contrainte de température (CT)

Une plage de température ambiante dans le DC de 21 à 23 °C est optimale pour la fiabilité du système. La plupart des sous-systèmes informatiques peuvent fonctionner à un niveau de température proche de 22 °C, ce qui est préférable car il est plus facile de maintenir des niveaux d'humidité relative associés.

Remarque : Les normes pour les différents fabricants et composants varient, donc il faut que le concepteur de DC vérifie les spécifications du fabricant pour les plages de température appropriées.

Également, au lieu d'utiliser uniquement les niveaux de mesure PUE comme norme désignée, les responsables de DC devraient prendre le temps de vérifier ASHRAE TC9.9 ASHRAE (2016) pour les températures de fonctionnement optimales des serveurs. Les normes ASHRAE recommandent qu'il y ait trois capteurs par rack. Ces capteurs doivent être placés en haut, au milieu et en bas du rack pour surveiller plus efficacement les niveaux de température environnants. Cette norme est bien respectée dans les deux cas d'utilisation qui seront décrits dans les prochains chapitres;

4. Contrainte d'humidité (CH)

Les niveaux d'humidité dans les salles de serveurs et dans les DCs doivent rester entre 40% et 60% d'humidité relative (HR) ASHRAE (2016). Ce qui est important pour la fiabilité et pour prolonger la durée de vie des sous-systèmes de DCs.

Qu'est-ce que l'humidité relative (HR)? L'humidité relative (HR) est la quantité d'humidité dans un échantillon donné d'air à une température donnée par rapport à la quantité maximale d'humidité que l'échantillon peut contenir à la même température. Si l'air retient toute l'humidité qu'il peut contenir pour un ensemble spécifique de conditions, il est dit qu'il est saturé (100 % de HR).

Remarque : Les variations de température ou d'humidité relative doivent être évitées. Les conditions ne devraient pas pouvoir changer de plus de 10 F (5,5 C) ou de 10% HR dans toute période d'exploitation de 60 minutes.

2.3 M2- Définition générique de la métrique d'efficacité énergétique : PUE

Les DCs sont en constante évolution. Les applications, ainsi que les équipements informatiques et l'infrastructure qui les soutiennent, évoluent continuellement pour mieux répondre aux besoins des entreprises.

Les calculs d'utilisation d'énergie sont souvent basés sur une conception statique (c.-à-d. sans prendre en considération les charges de travail, les températures interne, etc.) variation plutôt que sur la configuration dynamique. La conception statique par rapport à la réalité dynamique d'un DC doit être considérée. Les améliorations se traduiront par des changements progressifs des étapes dans l'infrastructure au fil du temps (par exemple, des changements des serveurs, etc.). En outre, il est important de garder à l'esprit que lorsque la charge du trafic change dans un DC, le point de fonctionnement des sous-systèmes sur leurs courbes d'efficacité énergétique va changer.

D'où dans cette deuxième partie de méthodologie de recherche, nous redéfinissons la métrique d'efficacité énergétique PUE. Cette partie de méthodologie inclue principalement la partie génération de la méthode PPCGO.

Dans ce qui suit, nous allons détailler les différentes étapes ainsi que les paramètres et la formulation de la métrique de PUE.

2.3.1 Les objectifs du métamodèle

Le métamodèle présenté dans la section 2.2.1 détaille une vue granulaire et générique pour les DCs qui englobe tous les aspects des performances (par exemple les performances énergétiques, etc.) à la fois au niveau des installations et de l'infrastructure DC.

Également, le métamodèle sera une bonne référence pour les utilisateurs DCs. Le métamodèle (DCMM) présentés précédemment est bâtis en adoptant les objectifs ci-dessous :

- **RQ1 : conception pour la flexibilité et généralisation des designs pour les centres de données**

En effet, à partir du métamodèle proposé, les concepteurs de centres de données en tant que utilisateurs de métamodèle vont se baser sur ce dernier pour faire leur propre design « conception » de centre de données. S'assurer que la conception est flexible et facilement évolutive est essentiel à la réussite d'une conception à long terme. Une partie de la flexibilité rend la conception rentable. Chaque décision de conception a un impact sur le budget. Notamment, une entreprise peut être en train de planifier un centre de données pour des applications stratégiques, une autre pour tester des configurations à grande échelle qui seront envoyées dans un DC critique. Notre métamodèle, en tant qu'un document générique contient tout type de système dont un centre de données doit contenir ainsi que les contraintes qui aident les concepteurs de DCs pour valider leurs décisions de conceptions. Pour créer finalement un « design » conforme aux exigences et aux besoins de l'entreprise;

- **RQ2 : utiliser une conception modulaire**

Les DCs sont des systèmes très complexes et les systèmes complexes peuvent rapidement devenir ingérables. Notre métamodèle permet de créer des blocs de construction plus petits et plus faciles à gérer. Avec une modélisation par espace, les concepteurs vont avoir une idée sur les modules qui peuvent exister dans chaque partie d'un DC ainsi que les modules qui se connectent ensemble;

- **RQ3 : simplifier la complexité des centres de données**

Les DCs sont des systèmes très complexes au point de vue de complexité de l'infrastructures. En effet, les travaux connexes sur les centres de données présentent une vue partielle de DC et travaillent sur chaque partie séparément. Pour cette raison, on a fait appel à notre métamodèle pour donner une vue simplifier des systèmes formant tous types de DC;

- **RQ4 : définir les flux d'énergie à travers tous les systèmes de métamodèle**

A travers le métamodèle proposé, on peut instancier des modèles énergétiques en déterminant les systèmes définissant les flux énergétiques, allant des systèmes électriques, et des systèmes mécaniques pour arriver aux systèmes TI. Cet objectif nous ramène à définir le prochain objectif;

- **RQ5 : métamodèle et définition des indicateurs clés de performance (KPI)**

En se basant sur le métamodèle proposé, nous allons définir les paramètres et les systèmes qui font part de la définition générique des métriques PUE. Le but est d'optimiser les opérations des DCs. En effet, en utilisant la nouvelle définition des KPIs basé-métamodèle sera suivi par l'application de l'algorithme d'apprentissage machine profond DNN (Deep Neural Network) pour la prédiction des valeurs en fonction de temps.

2.3.2 Définition

Cette définition est basée sur le métamodèle déjà proposé dans la méthodologie M1. Tout d'abord, on va définir les instructions pour instancier et générer le modèle énergétique PFM (Power Flow Model) à partir de métamodèle. Le PFM est utilisé par la suite pour donner une définition générique de la métrique PUE. En effet, Ce modèle reflète les paramètres et informations pertinents dans la définition de la métrique d'efficacité énergétique PUE.

La métrique d'efficacité énergétique PUE est le rapport entre l'énergie totale consommée par le DC y compris l'énergie consommée par les sous-systèmes de l'espace électrique de DCMM ainsi que les pertes, l'énergie consommée par les sous-systèmes de refroidissement de l'espace mécanique de DCMM et l'énergie consommée par les sous-systèmes TI de l'espace TI de DCMM (y compris l'énergie à la sortie de PDU-TI et l'énergie consommée par racks et par serveurs ainsi que la charge de travail par rack). De plus, cette métrique mettra l'accent sur les caractéristiques environnementales extérieures du DC, en étudiant les caractéristiques météorologiques et géothermiques. La métrique PUE redéfinit met l'accent sur l'énergie plutôt que sur la puissance comme le fait la définition standard de PUE.




Figure 2.2 Définition de la métrique PUE

La métrique de PUE générique est définie comme l'énergie totale consommée par un DC y compris l'énergie consommée par les sous-systèmes de l'espace électrique de DCMM, énergie consommée par les sous-systèmes de l'espace mécanique de DCMM et l'énergie consommée par les serveurs e l'espace TI de DCMM. La somme de ces énergies est divisée par l'énergie consommée par les racks et serveurs de l'espace TI (voir Figure 2.2).

Cette métrique a comme paramètres d'entrée les conditions environnementales (température et humidité).

2.3.3 Génération de modèle énergétique

Notre approche pour calculer la métrique PUE à l'aide du métamodèle nécessite la génération d'une instance du modèle nommé PFM (Power Flow Model) à partir du modèle DCMM. En effet, l'un de processus de validation du métamodèle de DC implique une transformation des instances de DCMM en PFM, c'est-à-dire des concepts définis dans le métamodèle de système de DC vers des solutions spécifiques fournies par le métamodèle. Cette transformation permet de vérifier que les instances du métamodèle sont utilisées au déploiement de l'apprentissage de l'efficacité énergétique dans un contexte réel.

Également, pour terminer le processus de validation, il est nécessaire de vérifier que le métamodèle DCMM permet de définir de véritables modèles énergétiques conformément au modèle défini et testé dans des cas réels.

Le modèle de la transformation est conforme au métamodèle correspondant. Un générateur, basé sur le mappage, est utilisé pour produire une sortie. La sortie du générateur est une transformation du modèle d'entrée en utilisant la transformation de graphe (TG). La motivation de cette génération est que nous souhaitons réutiliser le modèle de sortie dans la formulation de la métrique de PUE.

La procédure générale de cette génération est spécifiée avec l'algorithme 1 ci-dessous.

Dans ce qui suit, nous utilisons ces notations de base :

- Model :: Package :: ModelElement,
- Package :: ModelElement.

L'algorithme de génération est basé sur les principales règles de mappage suivantes :

- GR1 : un DCMM-electricalPackage est mappé dans des classes pour calculer la puissance électrique dans PFM;
- GR2 : un DCMM-ITPackage est mappé dans des classes pour les sous-systèmes TI dans PFM. Mais nous devons nous arrêter uniquement sur la classe de rack informatique de MM-ITpackage;
- GR3 : un DCMM-mechPackage est mappé en classes de refroidissement PFM.

Algorithme 1 : Pseudocode d'algorithme de génération de PFM
--

Input: M instance of DCMM

Output: pf instance of PFM

begin

1 Create pf:: Coolingpkg ; Create pf :: Powerpkg; Create pf :: ITpkg;

2 For each $e \in dcm :: Mechpkg$ GenerationRule (e);

3 For each $e \in dcm :: ITpkg$ GenerationRule (e);

4 For each $e \in dcm :: electricalpkg$ GenerationRule (e);

end

L'un des points les plus cruciaux d'une transformation basée sur la réécriture de graphiques (qui est le métamodèle DCMM) est la stratégie pour trouver une correspondance. Si nous supposons que la multiplicité des rôles dans une association est un à un, nous avons une tâche facile car chacun des éléments de métamodèle peut être instancié en un seul élément de modèle (sauf si le modèle utilise l'héritage). Sans la relation d'héritage, nous ne pouvons générer qu'un seul lien pour chaque association, et un seul objet pour chaque classe, afin d'éviter l'indirection susmentionnée.

En raison de ce mappage un à un (1—1), la correspondance peut être considérée comme une forme de vérification de type :

- si un type d'objet est une classe spécifique, cet objet correspond à cette classe;
- la situation est exactement la même dans le cas des liens ('instance') et des associations entre les classes.

Si nous avons une relation d'héritage, nous suggérons une procédure simple : pour chaque classe qui a une classe de base, une liste doit être maintenue contenant le type de toutes les classes de base. Un objet de tout type dans la liste est considéré comme une correspondance.

En plus, nous définissons dans une autre étape les contraintes pour assurer la génération de PFM. Nous considérons trois types de contraintes : liées aux objets du modèle, c'est-à-dire les éléments du modèle (notés O. *), liés aux valeurs des objets (V. *) et liés aux liens des objets (L. *) :

- **O.1** : pour un type d'objet, une classe correspondante doit exister (équivalence de nom);
- **O.2** : la classe correspondante ne doit pas être abstraite;
- **V.1** : pour toutes les valeurs d'un objet, un attribut correspondant dans la classe correspondante (ou dans ses superclasses) doit exister (équivalence de nom);
- **V.2** : pour tous les attributs (hérités) d'une classe, un objet correspondant doit remplir une cardinalité minimale des valeurs;
- **V.3** : pour tous les attributs (hérités) d'une classe, un objet correspondant doit remplir la cardinalité maximale des valeurs;
- **V.4** : pour toutes les valeurs d'un objet, le type de la valeur doit être conforme au type de l'attribut correspondant (entier, chaîne, booléen, etc.);
- **L.1** : pour tous les liens d'un objet, une référence correspondante dans sa classe correspondante (ou dans ses superclasses) doit exister (équivalence de nom);

- **L.2** : pour toutes les références (héritées) dans une classe, un objet correspondant doit remplir une cardinalité minimale des liens;
- **L.3** : pour toutes les références (héritées) dans une classe, un objet correspondant doit remplir la cardinalité maximale des liens;
- **L.4** : pour tous les liens d'un objet, le type de l'objet cible doit être la classe définie par la référence (ou ses sous-classes).

Nous utilisons dans la mise en œuvre les contraintes définies ci-dessus avec les règles de génération pour générer le modèle de PFM comme détaillé dans la figure 2.3.




Figure 2.3 Modèle de PFM généré à partir de DCM

2.3.4 Les paramètres de la métrique PUE

La génération du modèle PFM nous ramène à identifier les sous-système clés (et par conséquent les paramètres pour chaque sous-système) pour définir la métrique d'efficacité PUE.

Les paramètres qui vont être utilisés pour calculer les métriques d'efficacité énergétique, sont classés en 3 classes : les paramètres pour les sous-systèmes TI, les paramètres de l'énergie électriques et les paramètres reliés aux systèmes de refroidissements ainsi que les pertes des sous-systèmes électriques lors de la conversion de la puissance en entrée. En plus, certaines contraintes vont être considérer lors de la formulation de la métrique de PUE.

Les facteurs influençant la consommation d'énergie sont :

- l'infrastructure de refroidissement (équivalent des systèmes mécaniques dans le métamodèle DCMM) ($E_{cooling}$),
- les sous-systèmes de technologie d'information (E_{IT}),
- les pertes de puissance de la distribution et de conversion électrique ($E_{electricalLosses}$),
- la consommation d'énergie électrique (E_{elec}).

Les paramètres dont nous avons besoin pour déterminer le PUE sont énumérés comme ci-dessous :

- température à l'intérieure de DC,
- température à l'extérieur de DC,
- alimentation du centre de données en entrée,
- consommation totale d'énergie du centre de données,
- humidité du DC,
- consommation d'énergie / rack,

- consommation d'énergie par serveur,
- charge de travail / serveur,
- charge de travail / rack,
- consommation d'énergie après la PDU,
- consommation d'énergie à la sortie de l'UPS,
- la consommation d'énergie de CRAC,
- la température des points de consigne de CRAC,
- vitesse du ventilateur de CRAC,
- température d'allée chaude,
- température d'allée froide,
- pertes de câbles à basse tension,
- pertes de câbles à haute tension,
- les pertes de transformateurs en moyenne et haute tension (les transformateurs à l'entrée de DC en cas d'énergie électrique Utility_power) : ces mesures seront prises après les transformateurs (Présentée par la classe Input_transformer),
- les pertes d'énergie des UPSs,
- l'énergie consommée par les tours de refroidissements (ventilateurs et pompes),
- énergie renouvelable consommée (en se basant sur le type de l'énergie non-renouvelable, le paramètre d'énergie va être multiplié par un facteur de pondération α en fonction de type d'énergie renouvelable alimentant le DC- Voir Tableau 2.1).

Le gaz naturel, le mazout et d'autres sources d'énergie non électriques doivent être inclus dans tous les calculs de PUE valides. Une fois converti en kWh, un facteur de pondération établi (voir Tableau 2.1) doit être appliqué pour comptabiliser chacune de ces sources d'énergie de remplacement en tant que kWh équivalent (comme illustré dans cette équation : kWh équivalent = énergie alternative kWh *kWh facteur de pondération) dans la somme de l'énergie totale du centre de données. De ce fait, le tableau 2.1 résume les facteurs de pondération établis par l'industrie pour les sources d'énergie alternatives courantes utilisées par les centres de données. Sachant que le facteur de pondération d'électricité = 1.


Remarque : Toute énergie électrique renouvelable générée en dehors des limites de l'installation du DC et utilisée dans l'installation doit être incluse dans les calculs du PUE en tant qu'électricité brute. Ainsi, l'utilisation de l'énergie solaire ou éolienne peut être considérée comme énergie verte, mais leur utilisation n'a aucun effet sur les valeurs PUE de l'installation du DC.

Tableau 2.1 Les différents facteurs de pondération en fonction de type d'énergie
Tiré de Sheehan (2013)

Source d'énergie alternative	Facteur de pondération kWh
Gaz naturel	0.31
Carburant	0.30
Autre carburant	0.30
Eau glacée	0.31
Eau chaude	0.40
Vapeur	0.43
Eau du condenseur	0.03

Par ailleurs, les paramètres liés à la consommation des serveurs seront considérés pour la nouvelle définition de PUE :

- consommation d'énergie / rack,
- consommation d'énergie par serveur,
- charge de travail / serveur,
- charge de travail / rack



Énergie consommée par l'équipement informatique.

PUE est un nombre dynamique qui change en fonction de charge des serveurs. En effet, Le serveur individuel est un lien essentiel dans cette chaîne de distribution d'énergie.

Les prochaines étapes consistent à adopter la même approche au niveau du serveur individuel que la formule initiale de Green Grid Jauregui (2011) de PUE a fait au niveau du DC.

En mesurant la puissance d'un serveur et en déterminant combien de cette puissance est consommée par la charge de travail informatique utile et combien de puissance est dissipée dans la conversion et la distribution d'énergie, ainsi que la gestion thermique du serveur, une mesure équivalente peut être utilisée pour optimiser les conceptions et réduire la l'énergie gaspillée.

En outre, la puissance de l'équipement informatique ou la puissance d'entrée appliquée à la prise du serveur doit ensuite être convertie et distribuée au sein du serveur pour faire fonctionner les charges du sous-système comme le processeur et la mémoire. Pour éviter la perte de puissance, le serveur doit avoir une efficacité de conversion élevée, une capacité de gestion de l'alimentation basée sur la technologie et une faible perte de distribution d'alimentation.

Si l'énergie totale de l'installation est directement appliquée à la charge de l'équipement informatique, le $PUE = 1.0$ obtenu peut être atteint, mais cela n'est pas réalisable. En effet, la puissance reçue du réseau de distribution doit être convertie et distribuée à des niveaux de tension pouvant être consommés par l'équipement du centre de données. Les conversions de haute tension pour avoir des basses tensions afin d'alimenter les équipements des DCs, provoquent des pertes. Ce qui est nécessaire est de prendre ces paramètres dans la formule de PUE :

- les pertes de câbles à basse tension,
- les pertes de câbles à haute tension,
- les pertes de transformateurs en moyenne et haute tension (les transformateurs à l'entrée de DC en cas d'énergie électrique Utility_power) : ces mesures seront prises après les transformateurs (Présentée par la classe Input_transformer),
- les pertes d'énergie des UPSs.

Les DCs nécessitent des infrastructures considérables simplement pour distribuer une alimentation électrique ininterrompue et stable. Cette transformation commence par les systèmes UPS (qui sont utilisés en cas de panne), vers les TS (y compris les STS et ATS : les systèmes utilisés pour transférer la puissance vers les UPS) pour arriver aux systèmes de PDU. Ces systèmes comme indique dans le métamodèle sont de deux types : Les sous-systèmes PDUs dans l'espace électrique utilisent pour distribues l'énergie vers tous les systèmes de DC et les PDU cote de racks (ou appelés aussi RDU), mais ils ont les mêmes fonctionnalités que les PDUs. En effet, les sous-systèmes PDU transforment la puissance de haute tension distribuée dans un DC à un niveau de tension approprié pour alimenter les racks.

La métrique PUE déclenche le besoin de minimiser l'énergie utilisée par l'infrastructure des DC. En effet, cette métrique permet aux opérateurs d'estimer rapidement l'efficacité énergétique des DCs, et de déterminer si des améliorations doivent être apportées. En plus, le fait de disposer un modèle précis et robuste de la métrique offre de nombreux avantages pour les opérateurs et les propriétaires de DC. Par exemple, la comparaison des performances réelles par rapport à la performance prédite pour tout ensemble de conditions données peut être utilisée pour l'alerte de performance automatique, pour améliorer l'efficacité des DCs en temps réel et pour le dépannage. Également, la nouvelle définition de PUE va prendre en compte deux paramètres (x,y) : $PUE_{x,y}$

- X : Niveau de précision de mesure (L1, L2, L3),
- Y : Période de fréquentation de collecte de données.

Tout en considérant comme hypothèse le niveau PUE (x=3) : (PUE3) fournit le plus haut niveau de précision pour la mesure la plus rigoureuse.

Mais, Il y a deux exceptions à cette règle :

- s'il n'y a pas d'UPS dans le DC, il faut mesurer à l'entrée de l'unité de distribution d'alimentation (PDU);
- si les UPS supportent des charges non-IT qui représentent plus de 10% de sa charge (ex : le HVAC est également sur ce compteur) et ne peuvent pas être sous-mesurés, il faut mesurer à l'entrée du PDU. Si la charge non-IT peut être sous-mesurée, il faut la soustraire et entrer le reste comme sortie UPS.

2.4 M3- Framework de prédiction de la métrique d'efficacité énergétique

2.4.1 Description

Les développements récents dans l'industrie des technologies de l'information et de la communication (TIC), conduits par les progrès de l'intelligence artificielle (IA), de la réalité augmentée et d'autres, modifient considérablement les relations économiques et sociales de la société moderne. La demande croissante des services et de ressources en ligne a introduit une énorme consommation énergétique des DCs, les épines dorsales des services informatiques en ligne.

Les DCs comprennent principalement trois catégories de sous-systèmes essentiels :

- l'équipement informatique utilisé pour le traitement, le stockage et la transmission des informations requises;
- une infrastructure de refroidissement qui assure l'évacuation efficace de la chaleur qui est constamment générée par l'équipement informatique déployé;
- des équipements de conversion et de secours pour assurer l'alimentation fiable de l'énergie nécessaire aux systèmes informatiques et de refroidissement.

Les interactions entre ces sous-systèmes rendent difficile de prédire avec précision l'efficacité du DCs. En plus, tester chaque combinaison de fonctionnalités pour maximiser l'efficacité serait difficile étant donné les contraintes de temps, les variations fréquentes de la charge informatique et les conditions météorologiques. De plus, les interactions entre les sous-systèmes de DC et les différentes variations de l'environnement (humidité, température extérieure, température intérieure, etc.) rendent le processus de prédiction de l'efficacité énergétique si difficile. Par conséquent, la gestion de l'énergie des DCs est trop complexe.

Également, l'Internet des objets (IdO) se développe rapidement, cela a permis d'augmenter considérablement l'instrumentation systèmes et sous-systèmes permettant une gestion basée sur les données et la capacité de recueillir et d'analyser des données avec une haute granularité provenant des sous-systèmes d'UPS, CRAC, ATS, PDU, serveurs, etc.

Cette évolution technologique permet une observation et une étude exhaustives des interactions des sous-systèmes DC en collectant en continu des données et en surveillant tous les sous-systèmes de DC. Dans ce but, nous proposons un modèle d'efficacité énergétique DC qui vise à prédire les valeurs de la métrique PUE. Un modèle de prédiction d'efficacité du DC permet aux opérateurs de simuler les configurations opérationnelles du DC sans effectuer de modifications physiques.

En effet, cette demande d'optimiser davantage la consommation d'énergie des centres de données côté infrastructure et la nature des interactions complexes entre eux ont conduit à explorer les techniques d'apprentissage automatique qui apprennent à partir les données collectées de manière opérationnelle pour prédire avec précision l'efficacité de l'utilisation de l'énergie (PUE) et créer un modèle de contrôle pour valider les résultats des tests. Cette recherche soulève la question : Pouvons-nous optimiser davantage la consommation d'énergie dans un DC en utilisant des techniques d'apprentissage automatique ?

À l'heure actuelle, il est très difficile pour un opérateur de prévoir l'effet d'un changement de configuration de l'installation sur la métrique de PUE avant d'adopter les modifications. Ceci est dû à la complexité des DCs et aux interactions entre plusieurs sous-systèmes. En effet, l'apprentissage par machine est bien adapté pour l'environnement du DC compte tenu de la complexité des opérations traitées par les DCs et de l'abondance des données de surveillance existantes.

Nous proposons deux modèles différents pour calculer et prédire la métrique de PUE en fonction de temps :

- le modèle de réseaux de neurones profond (DNN) en utilisant l'algorithme de back-propagation résiliente (Resilient backpropagation) comme algorithme d'entraînement;
- le modèle de LSTM combiné avec la technique d'attention (Attention-based LSTM);
- les deux modèles sont comparés avec un modèle de base MLP (celui de google Gao (2014)).

Dans ce qui suit, nous allons détailler les modèles de prédiction sélectionnés ainsi que l'approche adoptée pour la mise en place de ces modèles.

L'approche de modélisation des modèles de prédictions suit les étapes suivantes :

- prétraitement des données en entrées,
- analyse de sensibilité,
- modélisation des modèles de prédiction,
- validation des modèles,
- post-Analyse et interprétation.

2.4.2 Prétraitement des données

Avant que nous détaillions les modèles proposés, nous allons décrire deux étapes primordiales lors de la mise en place et l'implémentation des modèles basés sur l'algorithme de réseau de neurone (ce qui est le cas pour notre approche en adoptant les modèles DNN et attention-based LSTM).

La première étape est le nettoyage des données. Les valeurs manquantes sont remplacées par une valeur constante comme la dernière valeur connue. Dans notre cas, nous n'avons que quelques valeurs manquantes. Bien que les données brutes collectées aient un ensemble de caractéristiques liées au DC, certaines d'entre elles sont redondantes et le reste est étroitement lié à la valeur PUE déjà calculée.

La deuxième étape est la normalisation des données. En effet, et en répondant à cette question : Pourquoi les données doivent être normalisées avant de former un modèle DNN ou LSTM ? Par ailleurs, l'une des meilleures pratiques pour former des modèles à base des réseaux de neurones est de normaliser les données pour obtenir une moyenne proche de 0. La normalisation des données accélère l'apprentissage et conduit à une convergence plus rapide. En plus, les données collectées sont hétérogènes vu le comportement hétérogène des DCs. De telles caractéristiques hétérogènes ne facilitent pas la convergence du modèle et affectent également la sélection des caractéristiques, ainsi les données sont normalisées avant d'effectuer la sélection des caractéristiques.

Pour la normalisation des données collectées liées aux DCs, nous adoptons la méthode de normalisation de Min-Max. Pour chaque paramètre en entrée, la valeur minimale de ce paramètre est transformée en 0, la valeur maximale est transformée en 1 et toutes les autres valeurs sont transformées en décimales entre 0 et 1.

La normalisation min-max garantit que toutes les fonctionnalités auront exactement la même échelle mais ne gèrent pas bien les valeurs aberrantes. Pour gérer le problème des valeurs aberrantes, nous utilisons la technique du score Z. Nous trouvons le z-score pour chaque donnée collectée. Le score Z est une mesure statistique qui vous indique à quelle distance se trouve un point de données par rapport au reste de l'ensemble de données. Dans un terme plus technique, le score Z indique le nombre d'écarts types par rapport à la moyenne entre une observation donnée.

Si le score z est supérieur à 3, la valeur est classée comme une valeur aberrante. Le principe de la méthode du score Z pour détecter les valeurs aberrantes est d'éliminer tout ce qui est trop éloigné de zéro (le seuil est un score Z de 3 ou -3) pour être considéré comme une valeur aberrante. Cette mesure paramétrique prend deux paramètres: la moyenne et l'écart type. Pour calculer le score Z d'une observation, nous prenons la mesure brute, nous soustrayons la moyenne et nous la divisons par l'écart type.

Remarque : La moyenne et l'écart type sont calculés pour l'ensemble de données, alors que x représente chaque point de données. Cela signifie que chaque point de données aura son propre score z, tandis que l'écart moyen / standard reste le même partout.

Les modèles de prédiction de la métrique d'efficacité énergétique PUE nécessitent deux catégories d'entrées : les paramètres climatiques et les paramètres du système énergétique et TI. Cette dernière catégorie comprend les spécifications de l'équipement, les paramètres d'efficacité opérationnelle du système et les points de consigne de l'environnement intérieur. Les paramètres climatiques incluent la température extérieure et l'humidité relative. Les variations des paramètres climatiques ont un impact considérable sur la demande d'énergie en raison de leurs influences sur le scénario d'utilisation de l'économiseur choisi et sur l'efficacité du refroidisseur. D'où une analyse de sensibilité est nécessaire à ce niveau et comme prochaine étape afin d'identifier les paramètres clés qui influencent la variation de la métrique de PUE.

2.4.3 Analyse de sensibilité

Une analyse de sensibilité a été utilisée pour identifier les paramètres d'entrée les plus importants qui affectent les valeurs de PUE résultantes. L'analyse de sensibilité est simplement l'analyse de l'influence des paramètres d'entrée du modèle sur les paramètres de sorties et ses caractéristiques. Les objectifs de l'analyse de sensibilité comprennent l'identification des paramètres d'entrée du modèle ou les combinaisons de paramètres d'entrée qui présentent le plus d'influence sur les caractéristiques de paramètre de sortie.

Cependant, l'analyse de sensibilité peut aider à hiérarchiser les paramètres qui doivent être contrôlés et / ou mesurés pendant les expériences de validation.

Une analyse de sensibilité basée sur la variance a été employée, en utilisant la méthode de **Sobol**, qui est une approche de sensibilité globale et dépendante du modèle pour décomposer l'incertitude des sorties du modèle attribué à des entrées spécifiques du modèle.

Remarque : l'analyse de sensibilité globale est plus robuste que l'analyse de sensibilité locale car la première prend en compte les interactions de paramètres tandis que la seconde ne peut évaluer que les changements de variables uniques.

D'où nous adoptons l'utilisation de l'analyse de sensibilité globale dans notre méthodologie de d'analyse de sensibilité.

L'analyse de sensibilité Sobol (qui est une méthode de paramètres d'entrée corrélés) est destinée à déterminer dans quelle mesure la variabilité de la sortie du modèle dépend de chacun des paramètres d'entrée, soit d'un seul paramètre, soit d'une interaction entre différents paramètres. Il convient de noter que l'analyse de sensibilité Sobol n'est pas destinée à identifier la cause de la variabilité d'entrée. Il indique simplement quel impact et dans quelle mesure cela aura sur la sortie du modèle. L'analyse de sensibilité Sobol est généralement utilisée pour les modèles de système complexes et décompose quantitativement la variance de sortie en fonction de ses ressources: c'est-à-dire à partir de paramètres individuels ou de l'interaction entre paramètres.

De ce fait, les indices de sensibilité d'ordre total sont généralement utilisés pour évaluer la contribution globale d'un paramètre et l'interaction avec d'autres paramètres. La taille de l'échantillon nécessaire pour effectuer une analyse de sensibilité Sobol fiable dépend de deux facteurs principaux :

- la complexité du modèle,
- le nombre de paramètres évalués.

Cette méthode est appliquée en suivant les étapes suivantes :

- générer des échantillons à partir des paramètres du sous-système climatique et énergétique (tableau des paramètres de PUE);
- exécuter les vecteurs d'échantillons à travers le modèle PUE;
- calculer les indices de sensibilité de **Sobol** et analyser les résultats de sensibilité.

Les étapes pour la mise en place de modèle de sensibilité en utilisant Sobol sont :

- déterminer les entrées du modèle (paramètres) et leur plage d'échantillonnage;
- exécuter l'exemple de fonction pour générer les entrées de modèle;
- évaluer le modèle à l'aide des entrées générées, en enregistrant les sorties du modèle;
- exécuter la fonction d'analyse sur les sorties pour calculer les indices de sensibilité.

Les indices de sensibilité Sobol ont plusieurs caractéristiques, qui peuvent être classées comme suit :

- les indices de sensibilité de type total, premier et deuxième ordre sont des valeurs positives;
- les paramètres avec des indices de sensibilité supérieurs à 0,05 sont considérés comme significatifs;
- la somme de tous les indices de sensibilité doit être égale à 1;

- les indices de sensibilité d'ordre total sont supérieurs aux indices de sensibilité de premier ordre.

De plus, pour évaluer la précision des résultats de sensibilité, la méthode **bootstrap** (avec 100 fois d'échantillonnage avec remplacement) a été utilisée pour calculer des intervalles de confiance à 97% pour les indices de sensibilité.

Le scikit-learn fournit une fonction qu'on a utilisé pour rééchantillonner l'ensemble de données pour la méthode bootstrap. En effet, la bibliothèque scikit-learn fournit une implémentation qui créera un échantillon bootstrap à partir d'un ensemble de données. Cette fonction est : `resample()` scikit-learn function⁴.

2.4.4 M3-1 : Modèle de Réseau de neurones profond (DNN)

Le modèle que nous proposons est basé sur l'approche de l'apprentissage machine profond et en particulier réseau de neurone profond (Deep Neural Network DNN). Le modèle DNN réussit assez bien à modéliser des problèmes complexes. De plus, le succès des DNN dépend de son architecture, notamment du nombre de neurones pour chaque couche, de l'algorithme d'apprentissage et de la sélection des fonctionnalités et des fonctions d'activation.

En outre, les modèles DNN sont idéaux pour les systèmes complexes qui ont un grand nombre d'états opérationnels, ce qui est le cas des DCs. D'où, nous proposons une approche d'apprentissage automatique qui tire parti de la disponibilité de données collectées pour développer un modèle mathématique qui comprend les relations entre les paramètres opérationnels et l'efficacité énergétique globale en calculant la métrique (PUE).

⁴ <https://scikit-learn.org/stable/modules/generated/sklearn.utils.resample.html>.

Dans ce fait, les réseaux neuronaux profond (DNN) réussissent assez bien à modéliser la non-linéarité et possèdent des caractéristiques telles que la capacité de généraliser l'adaptabilité et le fonctionnement en temps réel. Trouver une structure de réseau appropriée et trouver des valeurs de poids optimales font de la conception des algorithmes DNN un problème d'optimisation difficile. En d'autres termes, le succès des algorithmes DNNs dépend en grande partie de l'architecture, de l'algorithme d'entraînement « training algorithm » et du choix des fonctionnalités utilisées dans le « training ».

L'algorithme de rétropropagation (BP) est l'algorithme de formation DNN le plus populaire. En effet, l'algorithme de BP est un algorithme d'apprentissage supervisé qui permet au réseau de mettre à jour les poids des réseaux de neurones pour optimiser la fonction objective. L'erreur est propagée vers l'arrière à une couche précédente en calculant les gradients de la fonction de perte. Cela signifie que les gradients ont tendance à devenir plus petits à mesure que le calcul se poursuit.

Il s'agit d'une méthode de gradient qui vise à minimiser, par exemple, l'erreur quadratique moyenne totale (RMSE) entre les valeurs de sorties réelles et prédites. Bien que BP ait été appliqué avec succès à divers problèmes, il présente un certain nombre d'inconvénients dus à sa nature de gradient descente.

Parmi les problèmes de BP, le processus d'apprentissage est lent, le problème avec le minimum local et les difficultés à former de grands réseaux DNNs, c'est-à-dire des réseaux avec un grand nombre de couches et de neurones. Pour résoudre ces problèmes, on va appliquer l'algorithme DNN avec l'algorithme de « Resilient Back-Propagation : ReBP »

Contrairement à l'algorithme de rétropropagation, la rétropropagation résiliente n'a pas besoin de calculer les dérivées de la fonction d'erreur, elle utilise uniquement le signe de la dérivée pour déterminer la direction de la mise à jour du poids et peut donc fonctionner avec des méthodes non différentiables ou même non continues.

Par rapport à l'algorithme de rétropropagation traditionnel, l'algorithme de rétropropagation résilient offre une convergence plus rapide et est généralement plus capable de s'échapper des minimas locaux. La rétropropagation résiliente (ReBP) est un autre algorithme d'apprentissage utilisé pour entraîner les réseaux de neurones profond (DNN). ReBP, un type de processus itératif, utilise le même concept de gradient. Il possède deux caractéristiques importantes, il entraîne le réseau de neurones plus rapidement et, d'autre part, il ne nécessite aucun paramètre gratuit comme le taux d'apprentissage.

Le modèle DNN proposé comporte plusieurs couches qui comprennent un grand nombre de neurones, répartis en plusieurs nombres de couches. Ils sont utilisés pour concevoir des mécanismes d'apprentissage supervisé. Ainsi, l'architecture DNN contient une matrice d'entrée qui est un tableau ($n * m$) où n est le nombre d'exemples d'apprentissage en entrée du modèle.

Pour le modèle DNN, chaque neurone effectue des calculs simples mais les données d'entrée passent par plusieurs couches de calcul avant de produire une sortie. La matrice d'entrée est multipliée par des poids. Les résultats de la première couche de neurones servent d'entrée au calcul de la couche suivante et ainsi de suite.

Le DNN fera toutes les combinaisons possibles entre les différentes fonctionnalités afin de rechercher une bonne combinaison et les résultats de sortie précis $y' = \text{predictedPUE}$. Nous répétons la phase d'apprentissage plusieurs fois avant de trouver une architecture qui modélise correctement le jeu de données.

Cette opération comprend l'ajout ou la suppression de calques et la modification de leurs paramètres. Sur la base de ces processus, l'architecture proposée contient 12 couches dont 1 couche d'entrée, 1 couche de sortie et 10 couches cachées.

Dans ce qui suit, nous détaillons les phases de mise en œuvre du modèle DNN : dans la phase d'apprentissage, nous avons appliqué quatre étapes:

- initialiser aléatoirement les paramètres du modèle w ;
- implémenter l'algorithme de propagation directe;
- calculer la fonction de coût $F(w, d)$;
- implémenter l'algorithme de propagation avec retour en arrière (backPropagation).

Afin de calculer les paramètres des réseaux tels que les poids et les biais de chaque couche, nous utilisons la descente de gradient stochastique. Pour cela, nous avons besoin de gradients de F_i , qui est la fonction de coût pour le i ème exemple de formation.

Ensuite, l'algorithme du gradient stochastique sélectionne un sous-ensemble de données choisi au hasard et l'entraîne avec une approximation de gradient calculée à partir de ces mêmes données, et ainsi de suite. Jusqu'à ce que nous ayons épuisé toutes les données d'entraînement.

Pour les approches proposées, les performances sont évaluées à l'aide de métrique de la racine d'erreur quadratique moyenne (RMSE).

La méthodologie proposée comprend principalement quatre parties :

- prétraitement des données : Notre fournisseur de données a déjà appliqué une technique de prétraitement des données et nous donne un ensemble de données propre et utile. Ensuite, nous étudions les données fournies afin de les comprendre et nous pouvons ensuite analyser les résultats de sortie DNN (Voir section 2.4.2 et 2.4.3);
- division des données : nous divisons l'ensemble de données fourni en trois sous-ensembles : (1) ensemble de donnée utilisé pour la phase de formation, (2) ensemble de données pour valider le modèle DNN, et (3) ensemble de données pour la phase de test DNN. Le pourcentage de chaque sous-ensemble est déterminé après plusieurs itérations;

- définition de l'architecture DNN: à ce stade-ci, nous définissons l'architecture DNN: le nombre de couches cachées, le nombre de neurones pour chaque couche et la fonction d'activation qui doit être appliquée pour chaque couche;
- implémentation DNN: nous avons utilisé un moteur d'apprentissage qui apprend de l'ensemble de données fourni de manière opérationnelle et prédit l'efficacité énergétique en se référant à la prédiction métrique PUE. La validation de l'implémentation DNN est réalisée à l'aide de la métrique RMSE. De plus, le modèle DNN mis en œuvre vise à comprendre les relations entre les paramètres opérationnels (caractéristiques d'entrée) et l'efficacité énergétique globale.

Finalement, le réseau DNN en tant qu'une boîte noire nécessite une explication des résultats obtenus.

Dans ce cas la capacité de donner des aperçus significatifs à la boîte noire des modèles DNN peuvent fournir une explication sur la façon dont les divers paramètres du système affectent sa sortie. Ce bénéfice présente un intérêt car des informations utiles et nouvelles peuvent être obtenues pour améliorer les caractéristiques et les performances du système.

Dans ce cadre, nous allons proposer une approche combinant l'algorithme de DNN et une post-analyse des résultats de prédictions. Cette analyse va permettre de déterminer les facteurs clés contribuant à la consommation d'énergie dans les DCs.

2.4.5 M3-2 : Modèle Réseau de neurones récurrent (LSTM)

Les réseaux de neurones LSTM sont développés pour résoudre le problème de la disparition du gradient. Dans un réseau LSTM, on parle des blocs de mémoire. Les blocs de mémoire de LSTM fonctionnent en fonction de la synchronisation des informations, ce qui permet au réseau de stocker et d'accéder aux informations sur des périodes plus longues. Ces portes (y compris la porte d'entrée, la porte d'oubli et la porte de sortie) déterminent que l'unité LSTM doit maintenir, mettre à jour ou supprimer les informations d'état de la cellule.

Dans cette section, nous donnons tout d'abord une description de fonctionnement de modèle LSTM en particulier les cellules LSTM. Par la suite, nous décrivons le modèle LSTM proposé, les paramètres de conception et la structure de notre proposition ainsi que les étapes pour définir le Modèle finale de LSTM combiné avec la technique d'attention.

2.4.5.1 Description du modèle LSTM

Le modèle de mémoire à court terme à long terme (LSTM) est utilisé pour résoudre les problèmes de disparition de gradient pour la prédiction de la métrique de PUE




Figure 2.3 La structure de la cellule LSTM
Tirée de Varsamopoulos, Bertels, et Almudever (2018)

La figure 2.4 décrit la structure interne de la cellule LSTM, qui contient trois unités de déclenchement principales : porte d'oubli, porte d'entrée et porte de sortie. Ces portes permettaient au LSTM de conserver ou jeter des informations.

Avec :

- f_t , i_t et o_t représentent respectivement l'oubli, l'entrée et la sortie déclencheur des signaux au temps t ;
- $\sigma(\cdot)$ est une fonction sigmoïde logistique dont les valeurs sont comprise entre 0 et 1 ;

- $\tanh(.)$ est une fonction d'activation tangente hyperbolique qui donne des valeurs comprises entre -1 et 1;
- x_t : Représente l'entrée au temps t ; w_f , w_i et w_o sont les poids de chaque partie du réseau LSTM, et b_f , b_i et b_o représentent leurs biais.

Le processus de calcul au sein d'un bloc LSTM est le suivant :

- La valeur d'entrée ne peut être conservée dans l'état de la cellule que si la porte d'entrée le permet. La valeur d'entrée de i_t et la valeur candidate des cellules de mémoire, $\tilde{C}_t$, au pas de temps, t .
- la sortie de la cellule peut être bloquée par la porte de sortie, et toutes les portes utilisent la non-linéarité sigmoïdale, et l'unité d'état peut fonctionner comme une entrée supplémentaire pour d'autres unités de porte. Grâce à ce processus, l'architecture LSTM peut résoudre le problème des dépendances à long terme avec de faibles coûts de calcul.

2.4.5.2 L'approche de réseau LSTM avec le mécanisme d'attention

La sortie d'une cellule LSTM peut ne pas pouvoir capturer les informations des entrées à long terme en raison de sa mémoire limitée. Afin de corriger cette limitation, nous proposons de combiner le modèle LSTM avec le mécanisme d'attention. Dans ce cas, le mécanisme d'attention permet d'améliorer les performances du modèle LSTM dans le traitement de l'ensemble de données d'entrée à long terme. En effet, pour obtenir une prédiction précise, il est important de modéliser et de représenter les interdépendances dans les données en séries chronologiques.

De plus, la valeur ajoutée de combiner le mécanisme d'attention avec le modèle LSTM est qu'il permet au modèle LSTM d'examiner les informations à chaque pas de temps précédent, puis de sélectionner les paramètres pertinents pour calculer les sorties.

En outre, la couche d'attention apprend à partir du poids de la séquence d'entrée et calcule la moyenne de la séquence pour obtenir les informations pertinentes. En outre, le mécanisme d'attention assure la sélection des fonctionnalités. Le modèle ne peut conserver que les informations les plus utiles à chaque étape d'opération du modèle LSTM.

On commence par initialiser les paramètres du modèle LSTM, puis les données d'entrée sont transmises séquentiellement aux cellules de la couche LSTM. Comme le mécanisme d'attention est implémenté entre 2 couches LSTM, chacune de ces dernières prend la valeur de sortie de la cellule précédente et l'utilise comme entrée dans la couche d'attention. Également, il existe différentes approches pour mettre en œuvre un mécanisme d'attention.

Dans cette recherche, l'algorithme de Bahdanau Bahdanau, Cho, et Bengio (2014) est utilisé dans le mécanisme d'attention. En adaptant cet algorithme à notre problème de prédiction. De ce fait, cet algorithme est appliqué en calculant un vecteur C_t , appelé vecteur d'attention, à chaque pas de temps. Pour calculer ce vecteur (C_t), tout d'abord, il faut calculer e_t à chaque pas de temps en fonction de l'état caché h_t du modèle LSTM. Avec, e_t est le score de modèle qui décrit la correspondance entre une entrée à la position i et une sortie à la position t . Avant d'utiliser ce score par le modèle, il faut le normaliser en utilisant la fonction softmax. La valeur de score normalisé sera utilisée par la suite pour calculer le vecteur C_t , qui est à son tour utilisé pour calculer l'état caché de la couche suivante.

2.4.6 Métriques de comparaison

Une étude comparative qui est basée sur des mesures de performance en utilisant les indicateurs de performance tels que RMSE (Root Mean Square Error) et MAE (Mean Average Error) et le coefficient de détermination (R^2). Plus les valeurs RMSE et MAE sont petites, plus la valeur prédite est proche de la valeur réelle; plus le coefficient R^2 est proche de 1, meilleure est l'ajustement du modèle.

RMSE (Mean Square Error) est l'erreur quadratique moyenne d'un estimateur. Elle permet de mesurer la moyenne des carrés des erreurs - c'est-à-dire la différence quadratique moyenne entre les valeurs estimées et ce qui est estimé.

MAE est une mesure couramment utilisée pour évaluer la précision des prévisions et correspond à la valeur moyenne de la somme des différences absolues entre les valeurs réelles et prévues.

Le coefficient de détermination (R^2) est le carré de la corrélation entre les valeurs y prévus et les valeurs y réels; ainsi, il varie de 0 à 1.

CHAPITRE 3

METAMODELE DE CENTRE DE DONNEES ET VALIDATION

3.1 Introduction

Dans ce chapitre, nous présenterons les résultats de performance des deux modèles de prédictions et les analyserons : la première section décrit le métamodèle DCMM en générant des modèles énergétiques des DC réels et en validant les contraintes définies auparavant. Tandis que la seconde partie de ce chapitre traite les résultats des modèles de prédictions suivie d'une partie analyse et interprétation. La validation des solutions proposées est effectuée pour deux cas d'utilisation de deux modèles différents de DC dans deux localisations différentes et avec différentes caractéristiques et dimensions.

3.2 Métamodèle de centre de données (DCMM) et validation

La validation de métamodèle proposé est importante pour prouver l'efficacité et l'applicabilité de ce modèle dans des scénarios réels.

Afin de valider le modèle de DCMM, nous admettons le scénario de génération de modèle énergétique PFM qui sera utilisé par la suite pour identifier et définir les sous-systèmes et paramètres de calcul de la métrique de PUE. Et nous évaluons l'applicabilité de notre approche à travers deux cas d'utilisation, le premier cas est celui du Consortium Laval-UQAM-McGill et Est du Québec (CLUMEQ) DC et le deuxième centre de données est ITEA3 RISE (Ericsson DC localise au Suède). Les étapes sont : (1) Modéliser le DCMM, (2) Définir les contraintes OCL associées, (3) Définir les règles de transformation, (4) Générer le modèle de PFM, (5) Définir les paramètres de la métrique d'efficacité énergétique PUE, (6) Définir les modèles de prédiction et (7) Évaluer la performance des modèles de prédiction sur deux cas réels de DCs.




Figure 3.1 Métamodèle de centre de données

Le DCMM proposé présente une vue abstraite des différents sous-systèmes composant un DC, à savoir les sous-systèmes électriques, mécaniques, informatiques et de contrôle. Par conséquent, la structure globale du DCMM, représentée dans le diagramme de package UML de la figure 3.2, est composée de 4 packages (c'est-à-dire package électrique, package mécanique, package informatique et package de contrôle). Chaque package présente un espace DC (espace informatique, espace mécanique, espace électrique et espace de contrôle). Il existe des relations multiples entre les packages DCMM, comme le montre la figure 3.2.

À un certain niveau, il existe des interdépendances entre certaines classes de chaque package. Par exemple, la relation entre le package informatique et le package mécanique est une relation « d'utilisation » où certaines classes du package mécanique sont utilisées par les classes informatiques. Pour plus de détails, un DC peut généralement contenir un ensemble d'équipements informatiques disposés en racks informatiques. Ces équipements sont des classes du package. De plus, ces équipements génèrent de la chaleur, donc le DC doit être refroidi à l'aide d'unités de refroidissement, telles que les climatiseurs de salle informatique (CRAC) pour une gestion thermique efficace (le CRAC est une classe du package mécanique).




Figure 3.2 Structures en packages de DCMM

Tout au long de ce chapitre et comme méthode de validation, nous allons nous concentrer sur l'un des objectifs de DCMM et qui est la définition de flux énergétique à travers tous les sous-systèmes de métamodèle (voir section 2.7.2 – Chapitre 2 Méthodologie de recherche). Et en adoptant le RQ5 pour le reste de validation des résultats.

L'exigence de RQ5 indique que le DCMM définit les flux de puissance dans un DC pour identifier les systèmes définissant les flux d'énergie, allant des systèmes électriques aux systèmes mécaniques pour arriver aux systèmes informatiques. Cet objectif nous amène à définir le modèle de flux de puissance (PFM). C'est une génération d'un DCMM pour améliorer l'analyse d'efficacité énergétique.

3.2.1 Espace électrique de DCMM

Dans cette section, nous nous concentrons sur l'espace électrique DCMM (voir figure 3.3). Il s'agit d'un élément clé du métamodèle utilisé pour piloter la génération du modèle PFM, comme cela sera détaillé dans la section suivante.

Les principales classes de ce modèle sont les suivantes :

- classe ***InputPower***: Cette classe présente l'alimentation principale du centre de données. Il s'agit de la superclasse de deux classes qui héritent, à savoir la classe ***InputUtilityPower*** (c'est-à-dire l'énergie électrique) et la classe ***AlternatePower*** qui présente les sources d'énergie renouvelables (par exemple hydroélectrique, éolienne, solaire, etc.). Une haute tension. Cela nécessite donc d'utiliser un système de transformateur d'entrée. Par conséquent, la classe ***InputPower*** a une association directe avec une classe ***Input-Transformer***. Classe de transformateur d'entrée : Cela fait abstraction du système qui transforme le courant alternatif haute tension en courant alternatif moyenne ou basse tension. Cette transformation est nécessaire pour respecter la contrainte de transformation de puissance;
- classes ***Switchgear*** et ***SwitChboard*** : ces classes font abstraction des systèmes Switchgear et Switchboard, qui sont utilisés pour gérer les modes de fonctionnement du système d'alimentation d'entrée. Ces classes ont une relation d'association avec la classe ***TS*** (Transfer Switch);
- classe ***TS*** : La classe de commutateur de transfert est utilisée pour augmenter le temps moyen entre les pannes (Mean Time Between Failures : MTBF) du système grâce à la redondance des alimentations à l'aide du sous-système générateur. Il existe principalement deux classes qui héritent de la classe TS : la classe STS (Static Transfer Switch) et ATS (Automatic Transfer Switch). La classe TS a une ou plusieurs associations directes avec la classe UPS;

- classe *UPS*: Cette classe est une abstraction du sous-système qui permet au système d'alimentation du DC de continuer à fonctionner pendant au moins un court laps de temps lorsque la source d'alimentation principale est en panne.

Tout d'abord, nous allons décrire les différents package qui représentent respectivement l'espace électrique, mécanique et TI. Par la suite, nous allons appliquer les règles de génération pour générer le modèle énergétique.

Figure 3.3 Espace électrique de modèle DCMM

3.2.2 Les contraintes OCL de modèles

Les contraintes OCL peuvent être utilisées pour différentes raisons. Dans notre cas, nous les utilisons pour : (1) décrire les conditions préalables et postérieures aux fonctionnements de certains sous-systèmes et (2) préciser les contraintes sur les opérations des DCs :

- **contrainte d'électricité (CE)** : Cette contrainte est principalement utilisée pour garantir que la haute tension entrée pour alimenter le data center soit transformée en basse tension pour alimenter les équipements informatiques;

```
// Obtenir la classe UtilityPower à partir de package Electricalpkg
context UtilityPower::Transform-voltage(voltage : int)
pre : voltage = high
post : voltage = voltage@pre +transform.
If Electricalpkg .allInstances()→select(UtilityPower | UtilityPower.voltage
                                     >='600')
then  voltage = voltage@pre +transform.
endif
```

- **contrainte de haute tension (CHV)** : Cette contrainte est principalement utilisée pour garantir la haute disponibilité lors de l'alimentation de DC en assurant un basculement à partir de la source principale en cas de panne vers une source de secours temporaire UPS;

```
// Obtenir les classe UtilityPower et UPS à partir de package Electricalpkg
context UtilityPower::status: boolean init: false
if (Electricalpkg.utilityPower.status) → select(utilityPower|UtilityPower.status='down')
  then (UPS.status=1 else 0
    Select (TS|TS.status='up') // la classe TS remplace la classe UPS (TS est la source
de backup après 20 minutes de backup de UPS)
  endif
```

- **contrainte de température et RH**

Cette contrainte est utilisée pour garantir le respect de la température interne et aussi la valeur de l'humidité relative de DC. Une notification est envoyée au centre de contrôle de DC en cas d'une augmentation ou diminution des valeurs de température et RH, afin de garder le bon fonctionnement des sous-systèmes TI

```
// Obtenir les valeurs de temperature interne de DC // en cas d'une valeur 0 de temperature et de RH, le sous-système de contrôle sera alerté pour régulariser la température interne
```

```
contexte temperature: value: int, RH: value: float
```

```
  if(temperature.value) → select(temperature.status>='22' and temper.ature.status<='24')
```

```
    if (RH.value>40% and RH.value<65))
```

```
      then select (RH.value= actual value' else RH.value=" 0"
```

```
    then (temperature.value = actual value else temperature.value= "0")
```

```
      endif
```

```
    endif
```

3.2.3 Génération de modèle énergétique PFM

Notre approche du calcul de la métrique PUE à l'aide du modèle PFM nécessite la génération d'une instance du modèle PFM à partir du modèle DCMM d'un centre de données. Les modèles cible de la transformation sont conformes à leur métamodèle correspondant. Nous créons une représentation du mappage en termes de métamodèle. Un générateur, basé sur le mappage, est utilisé pour produire une sortie. La sortie du générateur est une transformation du modèle d'entrée. La motivation de cette traduction est que nous souhaitons réutiliser le modèle d'entrée dans un environnement qui prend en charge les concepts du modèle de sortie.

Pour définir le mappage entre deux modèles conceptuellement différents, il faut une base commune qui décrit à la fois les domaines source et cible de la transformation et le vocabulaire de la transformation. Cette base commune dans notre cas est le métamodèle. Nous considérons le métamodèle comme un ensemble d'éléments de métamodèle, et nous utiliserons la terminologie du diagramme de classes UML largement adoptée pour décrire le métamodèle. Les transformations basées sur les métamodèles n'utilisent que les éléments de métamodèle, ainsi la description de la transformation est exprimée en termes d'un modèle de sortie décrivant le flux d'énergie d'un DC.

Le processus de validation du métamodèle de DC implique une transformation d'instances de DCMM en PFM, c'est-à-dire des concepts définis dans le métamodèle DCMM vers des solutions spécifiques fournies par le métamodèle. Cette transformation permet de vérifier que les instances du DCMM sont réciproques au déploiement des modèles générés dans un contexte réel. Bien que cette transformation puisse être effectuée manuellement, l'utilisation d'un processus de mappage et la comparaison avec des modèles de DCs réel garantit sa validité et minimise le risque de biais.

En appliquant les règles de transformations sur le centre de données CLUMEQ, on obtient le modèle de PFM illustré à la figure 3.4.




Figure 3.4 Le modèle de PFM pour le centre de données CLUMEQ

L'infrastructure du DC CLUMEQ accepte en entrée l'alimentation de courant alternatif (CA) haute tension du fournisseur de services publics (Hydro-Québec), transforme sa tension et alimente les sous-systèmes UPS.

Ces sous-systèmes UPS se chargent généralement en continu et fournissent de l'énergie jusqu'à ce que les générateurs puissent démarrer lors d'une panne de secteur. À partir de sous-système UPS, l'électricité est distribuée à haute tension (600V) aux unités de distribution d'énergie (rack-PDU), qui régulent à leur tour la tension pour répondre aux exigences des sous-systèmes TI (IT-racks).

La totalité de l'énergie dissipée dans le DC CLUMEQ est convertie en chaleur, qui doit être évacuée de l'installation. L'élimination de cette chaleur tout en maintenant l'humidité et la qualité de l'air nécessite une bonne infrastructure de refroidissement. Le refroidissement commence par le sous-système de traitement de l'air de la salle informatique (CRAC), qui transfère la chaleur des serveurs vers une boucle de refroidissement eau glacée (présenté par la classe : ***WaterEconomizerCooling***) tout en fournissant de l'air froid dans tout le DC. Avec la localisation géographique de centre de données CLUMEQ, le refroidissement par air frais est utilisé. En effet, extraire la chaleur dans le DC CLUMEQ nécessite une énergie substantielle, la puissance de sous-système (***AirEconimizerCooling***) domine la puissance globale des sous-systèmes de refroidissement, et ses besoins augmentent avec la charge thermique du DC et la température de l'air extérieur.

Pour le flux énergétique de modèle PFM (voir Figure 3.4), la puissance en entrée du réseau électrique public (Hydro-Quebec) alimente le sous-système utility-power et le sous-système UPS. Par la suite, cette puissance est divisée entre les sous-systèmes IT et les sous-systèmes de refroidissement. En effet, l'alimentation TI est fournie via l'alimentation sans interruption (UPS). Le sous-système UPS alimente 12 racks informatiques, qui contiennent des serveurs et des unités de stockage de données, ainsi que des systèmes de réseau. Le sous-système UPS est également alimenté par des supports de stockage d'énergie, ***generator*** qui est une batterie de secours, en cas de panne d'alimentation électrique.

3.3 Conclusion

La conception de l'infrastructure du centre de données est complexe et doit être basée sur des normes de conception telles que l'infrastructure électrique, le système d'alimentation en air froid utilisé pour le refroidissement des équipements informatiques. En effet, le fonctionnement des sous-systèmes informatiques nécessite une alimentation constante 24/7 du sous-système UPS avec une température de 22 °C, 50% d'humidité relative par un sous-système de climatisation précis.

De ce fait, nous décrivons tout au long de ce chapitre les résultats de génération des modèles de PFM à partir d'un exemple réel de DC. Nous allons détailler dans le chapitre suivant les résultats d'implémentation des modèles de prédictions en tirant des conclusions sur l'applicabilité de ces modèles sur d'autres études de cas.

CHAPITRE 4

LES MODELES DE PREDICTIONS DE L'EFFICACITE ENERGETIQUE

4.1 Introduction

Dans ce chapitre, nous présentons les résultats obtenus de la mise en place des modèles de prédictions de l'efficacité énergétique en utilisant la métrique PUE.

De ce fait, l'approche de vérification et validation des modèles de prédictions suit les étapes suivantes et qui sont bien décrites dans le chapitre 2 :

- prétraitement des données en entrées,
- analyse de sensibilité et de corrélation,
- modélisation des modèles de prédiction,
- validation des modèles de prédictions de PUE,
- post-Analyse et interprétation.

En suivant ces étapes, et en appliquant les trois modèles de prédictions : le modèle DNN basé sur la propagation résiliente, le modèle LSM basé sur la technique d'attention et le modèle de MLP (MultiLayer Perceptron) comme modèle de base, nous obtenons des résultats d'implémentation qui seront détaillés dans les prochaines sections. Deux cas d'utilisations de deux modèles différents de DCs sont décrits afin de valider notre approche.

Remarque : La seule contrainte qu'on a eu durant la validation de nos solutions est le manque de données voulues pour le cas du CLUMEQ DC ainsi que la durée de collecte de données pour le cas ITEA3 RISE Sics DC.

4.2 Description des études de cas

Afin de valider les modèles de prédiction d'efficacité énergétique proposés, nous utilisons deux architectures différentes de centres de données dans deux localisations différentes et avec des technologies différentes.

4.2.1 Étude de cas 1 : Architecture de centre de données CLUMEQ (McGill-ETS)

Le DC CLUMEQ contient principalement deux parties : la première partie où l'équipement informatique est placé sur le rack UPS (rack SCV16 et SCV14) afin de l'utiliser pour la sauvegarde des données et la partie 2 où l'équipement informatique ne fait pas partie de système UPS (racks SCV2 à SCV12). De plus, le centre de données CLUMEQ utilise trois systèmes de refroidissement (refroidissement côté air, refroidissement par eau et système de refroidissement CRAC) ainsi que le refroidissement gratuit « free cooling ».

L'architecture de base de centre CLUMEQ est illustrée par la Figure 4.1 et les différentes caractéristiques sont bien résumées dans le Tableau 4.2.



Figure 4.1 L'architecture de centre de données CLUMEQ

Pour les caractéristiques de conception du CLUMEQ, on distingue :

- **capacité de refroidissement maximale** : 2 refroidisseurs de 200 tonnes = 400T (avec 1 RT = 3,5168525 kW, $400 * 3,5168525 = 1407\text{kW}$) + refroidissement par air libre,
- **exigence de charge au sol** : maximum 1 550 lb pour une surface de 2 pi x 4 pi (armoire à porte simple) ou 3 100 lb pour une aire de 4 pi x 4 pi (armoire à deux portes),
- **exigences de refroidissement** : toutes les armoires de la rangée 1 sont sur UPS et sont en rack standard de 19 pouces avec un flux d'air en avant et en arrière (front to back airflow),

- **les câbles (alimentation et réseau) sont à l'arrière** : pour les nœuds de travail (worker nodes), ils sont dans des racks avec des échangeurs de porte arrière de sorte que tout le câblage doit être fait à l'avant, ce qui signifie que toutes les terminaisons de câbles doivent être à l'avant,
- **distance** entre le chemin de câbles et le sol = 90 pouces au-dessus des armoires DDN et 86 pouces ailleurs.

En plus, les caractéristiques énergétiques sont comme ci-dessous :

- **puissance maximale** : 1350 kW (avec 1 kW = 0.28434517 RT, d'où $1350 * 0.28434517 = 384$ Tonnes),
- **capacité de refroidissement maximale de la pièce** : 2 refroidisseurs de 200 tonnes chacun 400. Avec 1 RT = 3.5168525 kW (RT : Ton of refrigeration) d'où $400 * 3.5168525 = 1407$ kW.

Pour l'alimentation électrique, CLUMEQ possède cinq types de circuits différents comme bien indiqué dans le tableau 4.1.

Tableau 4.1 Les types d'alimentation électrique du centre de données CLUMEQ

Type de circuit	La consommation (KW)
20A @ 208V	3.952
30A @ 208V	5.928
60A @ 208V	11.856
30A-3 phase @ 415V	20.48523
iDataplex double-door rack (3x30A-3 phase@208V)	61.45569

Pour les exigences de centre CLUMEQ :

- toutes les armoires de la rangée UPS sont en rack standard de 19 pouces avec un flux d'air d'avant en arrière,
- les câbles (alimentation et réseau) sont à l'arrière,
- pour les nœuds worker, ils sont dans des racks avec des échangeurs de porte arrière de sorte que tout le câblage doit être effectué à l'avant. Ce qui signifie que toutes les terminaisons de câbles doivent être à l'avant,
- hauteur du rack 42U est 80-82 ",
- hauteur du rack 45U est 87 ",
- hauteur de la porte d'entrée est 82 ".

Tableau 4.2 Résumé des caractéristiques de centre de données CLUMEQ

Les caractéristiques	Description
Niveau de redondance	N+1
Technologie de refroidissement	CRAC, Refroidissement à l'eau, refroidissement à air froide (Économiseur côté air).
Systèmes électriques	Puissance électrique d'Hydro-Québec, UPS, PDUs, Switchboards.
La capacité de puissance	Capacité de puissance maximale : 1350 Kw
La capacité de refroidissement	400 TR

4.2.1.1 Ensemble de données collectées pour le centre de données CLUMEQ

Les données collectées pour le DC CLUMEQ représentent une durée de 3 ans et 2 mois, détaillées comme suit : données collectées pour 2014, 2015, 2016 et durant le mois de Janvier et Février).

L'intervalle de collecte de données est de durée 5 minutes, allant de janvier 2014 à Février 2017. Également, les données collectées pour la température extérieure sont basées sur le site officiel de météo canada ⁵. Pour cette première étude de cas, on a identifié 10 paramètres, qui sont résumés dans le Tableau 4.3.

Tableau 4.3 Ensemble de paramètres en entrée pour l'étude de cas 1
CLUMEQ DC

Paramètres	Unité de mesure
Température intérieure	°C
Température extérieure	°C
Energie en entrée	KW
Consommation d'énergie CRAC	KW
Consommation d'énergie par rack	KW
Consommation d'énergie au niveau UPS	KW
Consommation d'énergie au niveau PDU	KW
Charge de travail par rack	%
Consommation totale de serveurs KW	KW
Workload /server	%

Un ensemble de capteurs sont placés afin de collecter les données tout au long de la période mentionnées (37 mois de collecte). Pour ce premier cas d'étude, les critères de collecte de données sont bien résumés dans le tableau 4.4. De ce fait, la charge informatique est dynamique tout au long de la période de collecte.

⁵https://climat.meteo.gc.ca/climate_data/daily_data_f.html?hlyRange=2013-02-13%7C2017-04-18&dlyRange=2013-02-14%7C2017-04-18&mlyRange=%7C&StationID=51157&Prov=QC&urlExtension=_e.html&searchType=stnName&optLimit=yearRange&StartYear=1840&EndYear=2017&selRowPerPage=25&Line=4&searchMethod=contains&txtStationName=Montreal&timeframe=2&Day=18&Year=2017&Month=3

Tableau 4.4 Résumé des informations de données collectées CLUMEQ DC

Critères de collecte de données	Cas 1
Date de début	2014-01
Date fin	2017-02
Durée	36 Mois
Plancher surélever [Oui / Non]	Oui
Configuration de la charge informatique [statique / variée]	Variée
Température moyenne Minimale °C	-10 °C
Température moyenne maximale	23 °C

Dans notre cas, nous avons juste quelques valeurs manquantes vu que la durée de collecte de données est restreinte. Donc, nous avons remplacé ces valeurs par la dernière valeur connue.

L'ensemble de données est divisé en trois sous-ensembles (ensemble de données d'entraînement, ensemble de données de validation et ensemble de données de test).

Avec un pourcentage fixé après plusieurs itérations à 60%, 20% et 20% respectivement pour l'entraînement, la validation et le test.

L'ensemble de données utilisé pour entraîner le modèle est créé à partir des données brutes collectées à partir des capteurs. Les données brutes sont traitées de manière uniforme, qui sont ensuite divisées en trois sous-ensembles :

- l'ensemble de données d'entraînement : cet ensemble de données est utilisé pour extraire les paramètres des modèles DNN et LSTM;
- l'ensemble de données de validation utilisé pour comparer les valeurs PUE prédites avec le PUE réel pour évaluer les performances des modèles proposés;
- un ensemble de données de test est sélectionné pour tester le modèle avec des données non utilisées.

4.2.2 Étude de cas 2 : centre de données ITEA3 RISE Sics ICE

Ce centre de données est localisé au Suède. Il est composé de deux modules (Module1 et Module2) représentant deux sous-espaces des centres de données. Chaque module abrite deux PODs (Performance-Optimized DataCenter) représentant le POD de l'infrastructure d'installation et le POD pour les sous-systèmes TI, comme illustré à la Figure 4.2.

Remarque : POD est l'approche modulaire d'un centre de données où les sous-systèmes fournis sont conçus comme une ligne complète ou une paire de lignes.




Figure 4.2 Vue d'ensemble de l'architecture de centre de données ITEA3 RISE Sics

L'architecture de DC présentée dans la figure 4.2 contient 440 serveurs avec 220 serveurs dans chaque POD. Les serveurs sont répartis sur 20 racks.

La taille de chaque rack est de 1200×800mm. En outre, les serveurs ont des fournisseurs différents et des caractéristiques différentes :

- 330 serveurs de type Dellr430,
- 96 serveurs de type Dellr530,
- 14 serveurs de type HPC700.

L'ensemble du DC est refroidi à l'aide de quatre refroidisseurs installés dans chaque module et la taille de chaque refroidisseur est de 1225 × 470 mm. Tous les sous-systèmes DC sont placés dans une zone DC de 16000 * 20000 mm.

On suppose que l'énergie consommée par les serveurs se transforme principalement en chaleur. La chaleur est évacuée par le flux d'air frais provenant de l'allée froide, qui traverse les serveurs vers l'allée chaude. Les ventilateurs du serveur et le ventilateur de l'échangeur de chaleur du module contribuent à ce flux d'air. L'air dégagé par les serveurs se mélange à l'air chaud de l'allée, qui est à son tour aspiré dans l'échangeur de chaleur par un courant d'air créé par le ventilateur situé dans l'échangeur de chaleur. L'air libère la chaleur dans l'eau froide circulant dans l'échangeur de chaleur. L'air refroidi sort de l'échangeur de chaleur vers l'allée froide, complétant la boucle d'air de refroidissement à l'intérieur du module. De même, la figure 4.3 illustre la vue numérique du module 2 du DC. Ce module abrite quatre unités de refroidissement placées autour de sa périphérie et 10 racks placés de deux côtés.

Pour la collecte de données, différents capteurs et appareils de mesure sont placés dans différents sous-systèmes et zones de DC. Pour le POD d'infrastructure, un dispositif de mesure de puissance est placé pour collecter la consommation électrique totale de l'installation. Dans l'IT POD, un appareil de mesure de puissance est placé pour collecter la consommation électrique informatique.

Un autre appareil de mesure de puissance est placé à l'entrée du DC pour collecter la puissance totale qui alimente le DC. De plus, la charge informatique du centre de données génère une grande quantité de chaleur.




Figure 4.3 Modèle numérique du centre de données ITEA3 RISE Sics ICE

4.2.2.1 Ensemble de données collectées pour le centre de données ITEA3 RISE Sics ICE

La sélection des paramètres se fait selon la définition générique donnée précédemment pour la métrique PUE. Ainsi, plusieurs critères tels que les caractéristiques des serveurs, les fabricants de sous-systèmes, le type de système de refroidissement, etc., sont pris en compte pour la définition de chaque fonctionnalité.

L'ensemble de données obtenu est une fonction de temps afin d'avoir une résolution cohérente d'une minute. La série chronologique pour tous les paramètres collectés commence le 24 mai 2018 et se termine le 25 mai 2018 (voir tableau 4.6).

Nous utilisons 60 secondes comme taux d'échantillonnage, allant de 9 h à 21 h. Le nombre total d'exemples est de 596 353 échantillons. Nous avons créé aléatoirement notre ensemble de données et l'avons divisé en partitions de 60% -20% -20% respectivement pour les ensembles de données d'entraînement, de validation et de test.

De plus, nous admettons les hypothèses suivantes. La chaleur générée par les sous-systèmes IT est transférée en utilisant l'éthylène glycol qui est le fluide caloporteur. Ainsi, nous supposons que l'eau avec seulement 30% d'éthylène glycol est utilisée pour alimenter les refroidisseurs. De plus, nous supposons que la technique de refroidissement côté air est utilisée pour le refroidissement de DC en bénéficiant de la localisation géographique. C'est pourquoi nous négligeons l'énergie consommée par certains sous-systèmes de refroidissement.

Comme le montre le tableau 4.5, nous avons résumé les 25 paramètres.

Tableau 4.5 Ensemble de paramètres en entrée pour l'étude de cas 1
ITEA3 RISE Sics DC

Paramètres	Unité de mesure
Température intérieure	°C
Température extérieure	°C
Energie en entrée	KW
Humidité relative intérieure ~ (HR)	%
Humidité relative de l'air extérieur	%
Consommation d'énergie CRAC	KW
Consommation d'énergie par rack	KW
Consommation électrique à la sortie d'UPS	KW
Consommation d'énergie après PDU	KW
Charge de travail par rack	%
Utilisation du processeur /server	Mgbit
Consommation totale de serveurs KW	KW
Workload /server	%
Température moyenne des allées froides	°C
Puissance du ventilateur CRAC	KW
Puissance utilisée par le liquide réfrigéré	KW
Vitesse du ventilateur	RPM
Puissance du ventilateur	KW
Température d'entrée d'eau glacée	°C
Point de consigne de température ambiante	°C
Point de consigne de température CRAC	°C
Température de l'allée chaud	°C
Température du bulbe sec à l'air extérieur	°C
Température du bulbe humide à l'air extérieur	°C
Puissance d'entrée aux PDU-rack	°C

De plus, la fonction de température de l'allée chaude est fournie en fonction des températures supérieures, centrales et inférieures mesurée à l'arrière de chaque rack. Ainsi, trois niveaux de mesure sont considérés pour calculer la fonction de température de l'allée chaude. De plus, pour la fonction d'humidité relative intérieure est calculée en plaçant le capteur d'humidité relative au milieu, à l'avant et à l'arrière de chaque rack.

La collecte de données pour les paramètres mentionnés ci-dessous est effectuée en plaçant des différents types de capteurs comme le montre la figure 4.4.




Figure 4.4 Emplacement des capteurs pour collecter les données du module 2 de ITEA3 RISE Sics.

Tableau 4.6 Résumé des informations de données collectées
ITEA3 RISE Sics

Nom de l'expérience	Cas 1a	Cas 1b	Case 2 (baseline)
Date de Début	2018-05-23	2018-05-23	2018-05-24
Heure de Début	09:00	21:00	09:00
Date fin	2018-05-23	2018-05-24	2018-05-25
Heure fin	21:00	09:00	09:00
Durée	12 Heures	12 Heures	24 Heures
Plancher surélever [Oui / Non]	Oui	Oui	Oui
Température de l'eau de refroidissement	20°C	15°C	20°C
Température de consigne de l'allée froide	25°C	25°C	25°C
Configuration de la charge informatique [statique / variée]	Statique	Statique	Statique
Répartition de la charge informatique	Inégale	Inégale	40% sur tous les racks

4.3 Les résultats numériques

Notre recherche est étroitement liée aux bibliothèques de logiciels open source. Le langage Python est le langage de programmation choisi. En outre, les bibliothèques NumPy, Pandas, Matplotlib sont importés pour le traitement, la gestion et la visualisation des données. Nous avons développé deux modèles (LSTM et DNN) basés sur TensorFlow qui est une bibliothèque de logiciels open source fournie par Google.

En effet, TensorFlow a été conçu à l'origine pour mener des recherches sur l'apprentissage automatique, l'apprentissage en profondeur et le calcul numérique à l'aide de graphiques de flux de données. Cependant, ce cadre est suffisamment complet pour être applicable à nos cas d'études. De plus, toutes les simulations ont été réalisées en utilisant un environnement de développement PyCharm sur un système informatique avec un processeur Core i7.

L'environnement de développement PyCharm, qui est un environnement de développement intégré Python, a pour configuration:

- une plateforme win32,
- une version Python 3.6.8,
- une version de pytest 5.3.2.

En outre, tensorflow et l'API Keras sont utilisés comme outil d'automatisation de ML.

Remarque : pytest est un framework qui facilite la création de tests simples et évolutifs. Les tests sont expressifs et lisibles - aucun code standard n'est requis.

4.3.1 Caractéristiques de la consommation des énergies

La consommation d'énergie de deux études de cas de DCs est influencée par plusieurs paramètres stochastiques. Ces paramètres incluent deux types de paramètres : ceux qui sont liés à la consommation des systèmes des DCs et ceux liés à la température extérieure qui affecte les sous-systèmes des économiseurs d'air.

L'analyse des différentes énergies utilisées pour calculer le PUE pour le cas d'étude de centre de données ITEA3 RISE Sics est présentée sur la Figure 4.5.

Comme le montrent les figures 4.5 et 4.6 respectivement, ces paramètres d'influence varient fortement au cours de l'année. La température de l'air intérieur et l'humidité relative sont également prises en compte pour évaluer leur influence potentielle sur les performances du modèle de prédiction.

En outre, une étude analytique des différentes énergies utilisées pour calculer le PUE est présentée dans la figure 4.5, indiquant la variation de l'énergie consommée à différents niveaux en fonction du temps. En analysant le jeu de données, nous concluons que l'énergie de refroidissement a une faible variation. Cette faible variation s'explique par l'utilisation de la technique de refroidissement gratuit via le sous-système économiseur côté air. Ce sous-système apporte de l'air frais de l'extérieur vers le DC. De plus, cette technique est utilisée pour maximiser l'efficacité énergétique en minimisant l'utilisation d'autres sous-systèmes de refroidissement tels que les CRAC. Par conséquent, on constate une faible consommation d'énergie des sous-systèmes CRAC.




Figure 4.5 Une distribution de différentes consommations d'énergie pour ITEA3 RISE Sics DC

Pour le cas de centre de données CLUMEQ, nous présentons dans la figure 4.6 les différents types d'énergies consommées par le DC ainsi que la variation de PUE durant la période de collecte de données.




Figure 4.6 Une distribution de différentes consommations d'énergie et le PUE
CLUMEQ DC

Sur la base de la localisation géographique du CLUMEQ DC (Montréal, Canada), nous profitons des températures extérieures en utilisant la technique de refroidissement gratuite avec le sous-système d'économiseur côté air. Ainsi, les données collectées pour la température extérieure sont basées sur le site officiel de « Climate Canada ». En effet, cette variation de température extérieure a une influence sur la consommation totale de l'énergie comme bien illustrée dans la figure 4.7.




Figure 4.7 Energie totale en fonction de la température extérieure
étude de cas CLUMEQ

Comme le DC CLUMEQ utilise la technologie de refroidissement gratuit comme technologie de refroidissement pour refroidir l'ensemble du DC. Ainsi, la baisse de température permet d'allonger sensiblement les périodes pendant lesquelles il n'est pas nécessaire d'utiliser la pompe à chaleur pour refroidir le data center. Dans ce cas, la charge de refroidissement sera diminuée, ce qui explique la variation des valeurs PUE entre 1,2 et 1,3. Ces valeurs sont calculées pendant la période froide de l'année (décembre, janvier, février). Sinon, le reste de l'année, la technologie « Free Cooling » n'est pas utilisée. Dans ce cas, nous reconnaissons que les valeurs PUE sont augmentées de 1,3 à 1,5. Sur la base de ces informations, nous évaluons l'effet de la température sur la métrique d'efficacité énergétique (PUE).

4.3.2 Résultats d'analyse de sensibilité

L'analyse des données est réalisée en utilisant deux techniques: Sobol et la technique de corrélation en utilisant la matrice de corrélation. En appliquant la technique sobol, nous sélectionnons les caractéristiques clés du modèle PUE, nous détaillons ci-dessous les résultats obtenus. Ainsi, le package Sensobol a été utilisé pour calculer les indices de sensibilité d'ordre total. Cette technique est utilisée pour les deux ensembles de données.

Pour évaluer les résultats de sensibilité Sobol, la méthode de bootstrap a été utilisée avec SALib (Sensitivity Analysis Library).

Pour cette méthode, deux paramètres principaux doivent être fixés (la taille de l'échantillon et le nombre de répétitions). Pour la taille de l'échantillon, c'est la même taille pour les deux ensembles de données expérimentaux. De plus, le nombre de répétitions est fixé à 250. Comme moyen de validation, 200 échantillons avec remplacement sont appliqués à chaque donnée après le prétraitement.

Les résultats de sensibilités appliqués sur les deux études de cas sont donnés respectivement dans les figures 4.8 et 4.9 pour l'étude de cas de centre de données ITEA3 RISE Sics. Alors que la figure 4.10 présente les résultats obtenus pour l'étude de cas CLUMEQ.




Figure 4.8 Résultats de l'indice d'ordre total Sobol Paramètres du sous-système de refroidissement pour l'étude de cas ITEA3 RISE Sics DC




Figure 4.9 Résultats de l'indice d'ordre total Sobol Paramètres du sous-système TI ITEA3 RISE Sics DC

Ces figures illustrent les caractéristiques avec leurs indices de sensibilité à l'ordre total Sobol. Ces indices montrent l'effet d'une caractéristique d'entrée sur le changement des valeurs PUE prédites.




Figure 4.10 Résultats de l'indice d'ordre total Sobol
étude de cas CLUMEQ

Pour les deux études de cas DC, la variance des caractéristiques climatiques extérieures DC (c.-à-d. Température extérieure, pourcentage d'humidité relative extérieure et température de bulbe sec de l'air extérieur) est l'un des facteurs importants de la variation du PUE. La température des sous-systèmes, comme la température moyenne des allées froides, la température d'entrée de l'eau glacée, les points de consigne de la température ambiante et la température des allées chaudes, est le deuxième facteur de variation du PUE.

Les résultats de sensibilité obtenus indiquent qu'il est très important de se concentrer sur la réduction de ces caractéristiques de performance (caractéristiques avec des indices sobol élevés) afin d'optimiser le PUE. Alors que la variance dans le sous-système UPS a une moindre contribution à la variation PUE, mais ce paramètre est toujours significatif. Parce que toute contribution pour minimiser les valeurs PUE présente une maximisation du gain d'énergie.

De plus, le facteur de charge de travail du serveur a un impact sur la consommation totale d'énergie du serveur, ce qui influence grandement la consommation d'énergie lorsqu'une variation dynamique est détectée. Cette fonction clé a donc contribué à la variation du PUE au fil du temps. Nous comprenons cet impact avec CLUMEQ DC où la configuration de la charge informatique est dynamique. Ce n'est pas le cas pour le centre de données TEA3-RISE-Sics (où la configuration de la charge de travail est statique).

Pour les résultats de corrélation en utilisant le diagramme Hinton, nous obtenons les relations entre les différents paramètres en entrées pour les modèles de prédictions. Ces résultats de corrélations ainsi que ceux d'analyse de sensibilités sont utilisés pour interpréter les résultats de sorties des modèles de prédictions proposés.

En effet, la corrélation est une mesure statistique de la façon dont deux ou plusieurs paramètres ont une relation de dépendance. Une corrélation positive indiquera des variables qui augmentent ou décroissent en même temps; une corrélation négative, en revanche correspond à une valeur qui augmente au fur et à mesure que le premier décroît.

En effet, les caractéristiques sélectionnées peuvent être indépendantes ou corrélées les unes aux autres, en déterminant la valeur du coefficient de corrélation. Dans notre cas, la corrélation est positive et le coefficient de corrélation est compris entre 0 et 1.

Plus le coefficient est proche de 1, plus la relation positive entre les caractéristiques est forte. Plus le coefficient est proche de 0, plus la relation entre les caractéristiques est faible.

De plus, la valeur de corrélation est classée en cinq classes: très faible (0,00 - 0,21), faible (0,22 - 0,40), modérée (0,41 - 0,60), forte (0,61 - 0,79) et très forte (0,80 - 1).

Comme le montre la Figure 4.8, nous observons que la consommation électrique du CRAC a une forte corrélation avec la température extérieure, suivie de l'humidité relative extérieure. Pour la première étude de cas (ITEA3RISE Sics DC), la puissance de refroidissement est produite en utilisant de l'air froid à travers les sous-systèmes CRAC, en plus de la technique de refroidissement par air « Free cooling». Cette dernière technique de refroidissement est utilisée, où l'air extérieur froid est directement injecté dans le circuit d'air de refroidissement des sous-systèmes informatiques via un économiseur côté air.

L'utilisation de la technique de refroidissement côté air dépend des conditions climatiques à l'extérieur du DC. Plus la température extérieure est basse, plus ce type de refroidissement sera utile et efficace. Par conséquent, la localisation DC est importante car elle comprend deux caractéristiques liées à la zone climatique extérieure (température extérieure, HR extérieure).

Cependant, la charge informatique totale du rack et les pertes de UPS ont une faible corrélation avec le paramètre de puissance d'entrée du DC où les facteurs de corrélation sont respectivement 0,25 et 0,37. Cette faible corrélation de la charge informatique du rack est due à la fixation d'une charge statique lors de la collecte des données. Au Canada, la température extérieure en hiver est basse, ce qui permet d'utiliser la technique du free cooling pour CLUMEQ DC.

Sur la base de la méthode de corrélation, nous pouvons conclure que la température extérieure a une corrélation élevée, en plus de la charge de travail par serveur et de la charge informatique totale par rack. Pour les deux derniers paramètres, nous pouvons expliquer cette corrélation par le fait que le charge de travail est dynamique pendant la période de collecte des données. De plus, ces fonctionnalités ont une forte corrélation avec la fonction de consommation totale du rack.

4.3.3 Résultats de prédiction avec DNN

Le modèle DNN proposé a plusieurs couches constituées d'un grand nombre de neurones. Ainsi, ces neurones sont répartis à travers plusieurs couches. Ils sont utilisés pour concevoir des mécanismes d'apprentissage supervisé.

La figure 4.11 illustre l'architecture DNN mise en place pour les deux cas d'étude avec n , qui représente les paramètres en entrées, lesquels sont fixés respectivement à 10 pour l'étude de cas CLUMEQ et 25 paramètres pour l'étude de cas ITEA3 RISE Sics Ice.




Figure 4.11 Topologie de réseau neuronal profond DNN proposée

Pour le modèle DNN, chaque neurone effectue des calculs simples mais les données d'entrée passent par plusieurs couches de calcul avant de produire une sortie.

Nous répétons la phase d'apprentissage plusieurs fois avant de trouver une architecture qui modélise correctement l'ensemble de données. Cette opération comprend l'ajout ou la suppression de couches et la modification de leurs paramètres. Sur la base de ce processus, l'architecture proposée contient 12 couches dont 1 couche d'entrée, 1 couche de sortie et 10 couches cachées. Le tableau 4.7 illustre l'architecture DNN définie.

Tableau 4.7 Le modèle numérique de l'architecture DNN

Type de couche	Nombres de neurones	Fonction d'activation (cas 1)	Fonction d'activation (cas 2)	Fonction d'activation (cas 3)
Entrée	N	Relu	Relu	Relu
Cachée	256	Relu	Leaky-Relu	Elu
Sortie	1	Linéaire	Linéaire	Linéaire

Le modèle d'architecture présenté dans le tableau 4.7 est implémentée pour les deux cas d'étude mentionnés auparavant. Cette architecture est fixée après plusieurs itérations et implémentée respectivement en utilisant deux algorithmes d'apprentissage (l'algorithme de propagation en arrière puis l'algorithme de backpropagation résiliente) pour optimiser les valeurs de prédiction. En outre, l'application de l'algorithme de rétropropagation résiliente (ReBP) fournit une solution pratique à la détermination du taux d'apprentissage et améliore la précision de la prédiction du modèle.

Cet algorithme est particulièrement utile pour les données complexes comme le cas de la consommation d'énergie du centre de données. L'algorithme ReBP (qui est caractérisé par un retour de poids) est un algorithme très flexible qui peut s'adapter aux changements de

complexité du modèle. Et cela aide à trouver une meilleure solution lorsque les spécifications du modèle changent.

Le Tableau 4.8 et le Tableau 4.9 présentent une comparaison entre les algorithmes d'apprentissage sélectionnés (rétropropagation et rétropropagation résilient) pour entraîner l'algorithme DNN sur la base de la précision pour les deux études de cas. Ainsi, l'algorithme de rétropropagation résilient est capable de converger plus rapidement vers une meilleure précision.

Tableau 4.8 Comparaison de la précision d'entraînement et des tests pour ITEA3RISE Sics

Algorithme d'entraînement	Précision d'entraînement (%)	Précision de test (%)
Back-Propagation	82	78
Resilient backproPagation	95	87

Tableau 4.9 Comparaison de la précision d'entraînement et des tests pour CLUMEC DC

Algorithme d'entraînement	Précision d'entraînement (%)	Précision de test (%)
Back-Propagation	80	75
Resilient backproPagation	93	85

On observe que le ReBP a montré une meilleure formation et une meilleure précision par rapport à l'algorithme de rétropropagation pour les deux ensembles de données.

Les résultats de précision des algorithmes d'apprentissage proposés pour le modèle DNN sont détaillés dans le tableau 4.9.

Après avoir sélectionné l'algorithme d'entraînement, nous définissons dans cette sélection l'architecture DNN. Une implémentation du modèle DNN basé sur la rétropropagation résiliente est réalisée après avoir défini les paramètres (nombre de couches, fonction d'activation, nombre d'époque, etc.).

Le modèle DNN basé sur le backPropagation Résilient permet d'effectuer toutes les combinaisons possibles afin de trouver des résultats de sortie précis (PUE).

Comme résultats de sortie pour l'étude de cas ITEA3-RISE-Sics DC, nous avons:

- temps d'exécution du modèle: 63,5 s,
- temps de prédiction du modèle: 0,0625 s.

Et le même modèle d'application pour CLUMEQ DC, donne les résultats:

- total des paramètres du modèle: 2 336 513,
- temps d'exécution du modèle: 86 s,
- temps de prédiction du modèle: 0,0788 s.

Trois fonctions d'activation sont sélectionnées et implémentées avec le modèle DNN: Relu, Elu et Leaky-Relu. Les résultats de modèle DNN avec les différentes fonctions d'activation sont présentés dans la figure 4.11, tout en montrant les valeurs prédites et les valeurs réelles de PUE. De plus, nous avons sélectionné RMSE comme métrique pour comparer les trois implémentations.

Sur la base des résultats obtenus dans le tableau 4.10, nous concluons que la fonction d'activation Leaky-relu convient à notre étude de cas en donnant la valeur RMSE la plus basse.

Tableau 4.10 Résultat de RMSE avec différentes fonctions d'activation
ITEA3RISE Sics DC

Fonction d'activation	Nombre d'époques	RMSE
Élu	550	0.00532
Leaky Relu	550	0.00261
Relu	550	0.00430

4.3.4 Résultats de prédiction avec le réseau de neurone récurrent (LSTM)

Le développement du modèle est effectué de façon à quantifier l'amélioration à chaque étape. La première étape consiste à développer un réseau de neurones LSTM en étudiant différentes topologies. Les caractéristiques d'entrée de cette étape sont les données de la consommation d'énergie pour les deux études de cas de DCs. Le nombre de couches a été fixé après plusieurs expériences.

Le modèle est formé de 4 couches:

1. Une couche d'entrée avec différents paramètres d'entrée,
2. Couche LSTM avec 200 unités cachées et de la fonction d'activation est Relu,
3. Deuxièmes couche LSTM avec 200 unités cachées et la fonction d'activation est Relu,
Le mécanisme d'attention est implémenté entre les deux premières couches LSTM,
4. La couche de sortie (PUE).

La couche de sortie est une couche de régression. Entre toutes les deux couches de l'architecture LSTM, nous appliquons le mécanisme d'attention.

Le taux d'apprentissage est fixé à 0,001 et l'algorithme d'optimisation d'Adam est utilisé pour l'optimisation du poids pendant la phase d'entraînement. Le nombre maximum d'époques a été fixé à 250 (ce nombre a été fixé après plusieurs itérations).

Les résultats obtenus des paramètres d'exécution donnent comme résultats pour l'étude de cas ITEA3 RISE Sics DC:

- colonnes: 417 entrées, timestamp , PUE,
- dtypes: float64 (407), int64 (10),
- utilisation de la mémoire: 9,2 Mo.




Figure 4.12 Résultat de prédiction avec attention-based LSTM
ITEA3-RISE-Sics DC







Figure 4.13 Résultats de prédiction avec DNN basé BackPropagation résilient
CLUMEQ DC



(a) Élu



(b) LR



(c) Relu

Figure 4.14 Comparaison des résultats DNN basé BackPropagation résilient
avec différentes fonctions d'activation
ITEA3-RISE-Sics DC

4.3.5 Résultats de prédiction et comparaison des modèles

Nous présentons les performances de prédiction des modèles sélectionnés: Google-MLP, DNN basé sur la propagation résiliente et le LSTM basé sur la technique d'attention.

Pour évaluer une comparaison des performances, nous utilisons MLP comme modèle de base pour fin comparatif. Ainsi, la précision de prédiction des différents modèles proposés (MLP, DNN, LSTM) est évaluée à l'aide de trois métriques: RMSE, MAE et coefficient de détermination.




Figure 4.15 Valeurs PUE prédites vs réelles des modèles sélectionnés
CLUMEQ DC

Les résultats numériques des modèles DNN basé sur la propagation résiliente et LSTM basé sur l'attention, ainsi que les différentes étapes, sont déjà présentés respectivement en détail dans les sections 4.3.3 et 4.3.4. En effet, les figures 4.17 et 4.18 présentent respectivement les résultats obtenus sur toute la période de tests, respectivement, pour les centres de données CLUMEQ et ITEA3-RISE-Sics.




Figure 4.16 Valeurs PUE prédites vs réelles des modèles sélectionnés
ITEA3-RISE-Sics DC

Selon les résultats obtenus, les performances du modèle LSTM basé sur la technique d'attention sont significativement meilleurs que le modèle de base proposé par Google et celui de DNN basé sur la propagation résiliente. Encore pour prouver ces résultats, nous utilisons trois métriques RMSE, MAE et R2 qui donnent des valeurs plus faibles. Ces résultats sont détaillés dans les figures 4.17 et 4.18.

En effet, pour l'implémentation du modèle MLP de Google, le MAE est égal à 0,005, tandis que dans notre cas, nous obtenons une valeur minimale donnée de DNN basé sur la propagation résiliente avec la fonction d'activation Leaky-Relu égale à 0,00387 et une valeur maximale égale à 0,00465. Ces résultats sont améliorés avec les deux ensembles de données. Pour le modèle LSTM, la valeur de la métrique MAE est égale à 0,0026 et 0,0039 respectivement pour ITEA3-RISE-Sics DC et CLUMEQ DC (CLUMEQ (voir tableaux 4.11 et 4.12).




Figure 4.17 Mesures de performances des modèles sélectionnés
Cad d'utilisation CLUMEQ




Figure 4.18 Mesures de performances des modèles sélectionnés cas d'utilisation ITEA3-RISE-Sics

Nous concluons que le modèle LSTM basé sur la technique d'attention donne des résultats précis par rapport aux modèles de DNN et MLP propose par le travail de Google Gao (2014). En effet, le temps d'exécution du modèle LSTM basé sur la technique d'attention est égal à 35 secondes et respectivement pour l'étude de cas ITEA3-RISE-Sics et CLUMEQ. Alors que celui de modèle MLP est égal à 89 secondes et 110 respectivement pour l'étude de cas ITEA3-RISE-Sics et CLUMEQ.

Tableau 4.11 Temps d'exécution des modèles de prédiction
Cas d'utilisation ITEA3-RISE-Sics

Nom du modèle	Temps d'exécution (s)
DNN basé sur Rebackproagation	63.49
LSTM basé-attention	35
MLP	89.32

Tableau 4.12 Temps d'exécution des modèles de prédiction
Cas d'utilisation CLUMEQ

Nom du modèle	Temps d'exécution (s)
DNN basé sur Rebackproagation	86
LSTM basé-attention	43
MLP	110

De plus, le modèle LSTM basé sur la technique d'attention donne une optimisation du PUE pour ITEA3-RISE-Sics DC avec 0,009 par rapport aux valeurs réelles (Le PUE réel moyen est égal à 1,059 et le PUE moyen prévu est égal à 1,050). Pour le CLUMEQ DC, les valeurs PUE sont améliorées avec une minimisation de 0,03 avec une valeur réelle moyenne égale à 1,308 et la valeur PUE moyenne prévue égale à 1,2730.

En analysant les résultats obtenus et avec l'application de l'approche d'analyse de sensibilité Sobol, nous pouvons conclure que toutes les fonctionnalités d'entrée ont un impact direct sur la variation et l'optimisation du PUE, mais en particulier les fonctionnalités de refroidissement ont principalement un bon impact sur l'optimisation du PUE. Dans ce cas, il existe de nombreuses façons de réduire les métriques DC PUE. Les systèmes de climatisation peuvent être la première étape. De plus en plus de DCs utilisent la méthode de free cooling qui permet de limiter le besoin de climatiseurs tels que (système CRAC).

Pour les deux études de cas, cette technique est appliquée compte tenu de l'emplacement des deux CD. La technique du free cooling ne peut pas être utilisée toute l'année, c'est pourquoi la mise en œuvre des sous-systèmes et la technique de refroidissement efficace permettent également de réduire la valeur PUE et par conséquent d'améliorer l'efficacité énergétiques des DCs. Et il faut penser à réduire l'énergie consommée par les sous-systèmes de refroidissement. Ceci est possible en donnant accès aux pratiques internes des DC et en se concentrant sur des pratiques plus efficaces. Ainsi, il est également possible de mettre en place des allées chaudes et des allées froides qui permettent une meilleure gestion des flux d'air et rendent les unités de climatisation plus efficaces. Comme mentionné dans les résultats de sensibilité de l'application de la méthode Sobol, ces deux caractéristiques clés ont une influence sur la variation du PUE. Par conséquent, ils auront un impact sur l'optimisation du PUE.

CONCLUSION

Les centres de données sont des systèmes complexes. Cependant, la variété des configurations et les interdépendances des sous-systèmes DC créent des défis dans la compréhension et l'optimisation des complexités DC.

Tout au long de cette thèse, nous nous sommes intéressés à la durabilité des DCs en définissant un métamodèle conceptuel qui donne un aperçu sur les différents sous-systèmes de DC. Cette approche de modélisation vise à contrôler la complexité de conception de l'infrastructure DC et à assurer la cohérence de ces conceptions. La pierre angulaire de notre approche est un métamodèle générique (DCMM), qui capture la structure hétérogène des DC, les principales caractéristiques et les diverses contraintes. De plus, nous avons proposé une méthode pour générer un modèle de flux énergétique (PFM) à partir d'un modèle de DC d'entrée. Le modèle PFM est alors utilisé pour identifier les paramètres de la métrique de PUE.

Ce dernier modèle a été validé par la suite par un modèle de prédiction de l'efficacité énergétique de la totalité de DC en faisant appel à la métrique de PUE. Nous proposons deux modèles d'apprentissage profond (resilient BackPropagation -based DNN and attention-based LSTM) pour une prédiction efficace. La validation est faite avec deux scénarios et ensembles de données réels et comparée à un modèle de base (MLP) proposé par Google.

Le modèle LSTM basé sur l'attention donne une prédiction avec précision de la métrique PUE sur une courte période de temps par rapport au modèle DNN basé sur la rétropropagation résiliente et au modèle Google-MLP. Comme résultats, nous avons observé une diminution de la valeur de PUE moyen de 0,005 pour le premier jeu de données et une optimisation de 0,03 pour le deuxième jeu de données (CLUMEQ DC).

Finalement, même si nous avons une petite minimisation du PUE, mais lorsqu'elle est appliquée à ITEA3 RISE Sics DC avec des centaines de serveurs, l'optimisation aura un impact

énorme. Et ce sera plus précieux avec un DC à grande échelle. En outre, toute optimisation doit tendre vers une réduction de la consommation d'énergie. En règle générale, l'adoption de techniques de refroidissement plus efficaces telles que le free cooling, le refroidissement par eau, etc., aide à réduire la consommation d'énergie des DCs mais aussi à améliorer l'efficacité énergétique en réduisant les valeurs PUE.

Notre travail présente certaines limites dues principalement à certaines lacunes dans les données collectées sur une courte période pour le premier ensemble de données. Alors que le deuxième ensemble de données, qui est collecté pendant une longue période, mais qui manque de détails, précisément les différentes fonctionnalités à différents niveaux de DC pour calculer avec précision les valeurs PUE et connaître les points d'inefficacité. Pour ce problème, nous ne pouvons garantir que des prédictions à court terme. Alors que pour avoir un bon suivi du PUE, nous avons besoin de prévisions à long terme et de beaucoup de données.

Par ailleurs, en raison de la difficulté de collecte de données suffisantes dans cette recherche, les données disponibles ont été utilisées pour une évaluation comparative. Selon la revue de la littérature réalisée, très peu de travaux de recherche se sont concentrés sur l'application du mécanisme d'attention dans le domaine de l'énergie et en particulier l'efficacité énergétique des DCs.

Ainsi, nous recommandons que d'autres études soient entreprises pour révéler les applications potentielles de notre méthode dans les systèmes énergétiques. De ce fait, les recherches complémentaires potentielles sont:

- Une évaluation comparative de différents mécanismes d'attention pour la prédiction de PUE à court et à long terme;
- Proposer un modèle d'optimisation de l'énergie des systèmes de refroidissement en ayant recours aux résultats de sensibilité Sobol.

LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES

- ASHRAE. (2016). Thermal Guidelines for Data Processing Environments. *American Society of Heating and Refrigerating and Air-Conditioning Engineers, Tech. Rep, 9*, 205.
- Association, T. I. (2010). TIA-942 Telecommunications Infrastructure Standard For Data Centers. *Arlington Virginia: Telecommunications Industry Assn.*
- Avelar, V., Azevedo, D., French, A., & Power, E. N. (2012). PUE: a comprehensive examination of the metric. *White paper*, 49.
- Avgerinou, M., Bertoldi, P., & Castellazzi, L. (2017). Trends in data centre energy consumption under the european code of conduct for data centre energy efficiency. *Energies*, 10(10), 1470.
- Bahdanau, D., Cho, K., & Bengio, Y. (2014). Neural machine translation by jointly learning to align and translate. *arXiv preprint arXiv:1409.0473*.
- Bhagwat, H., Singh, A. K., Jayaprakash, R., & Sivasubramaniam, A. (2016). Method and system for real time monitoring, prediction, analysis and display of temperatures for effective thermal management in a data center: Google Patents.
- Botterón, F., & Pinheiro, H. (2007). A three-phase UPS that complies with the standard IEC 62040-3. *IEEE Transactions on Industrial Electronics*, 54(4), 2120-2136.
- Bowling, A. (2014). Development Of Artificial Neural Network Based Black Box Model Of A Data Center As A Temperature Predicting Tool As A Function Of Server Location, Dissipating Server Heat And CRAC Fan Speed.
- Cho, J., & Kim, Y. (2016). Improving energy efficiency of dedicated cooling system and its contribution towards meeting an energy-optimized data center. *Applied Energy*, 165, 967-982.
- Commission, I.-I. E. (2016). IEC 62040-2.
- Dayarathna, M., Wen, Y., & Fan, R. (2015). Data center energy consumption modeling: A survey. *IEEE Communications Surveys & Tutorials*, 18(1), 732-794.
- DiMinico, C., & Jew, J. (2006). Telecommunications infrastructure standard for data centers ANSI/TIA-942.
- Farahnakian, F., Liljeberg, P., & Plosila, J. (2014). Energy-efficient virtual machines consolidation in cloud data centers using reinforcement learning. Dans *Parallel*,

Distributed and Network-Based Processing (PDP), 2014 22nd Euromicro International Conference on (pp. 500-507). IEEE.

Farahnakian, F., Pahikkala, T., Liljeberg, P., & Plosila, J. (2013). Energy aware consolidation algorithm based on k-nearest neighbor regression for cloud data centers. Dans *Utility and Cloud Computing (UCC)*, 2013 IEEE/ACM 6th International Conference on (pp. 256-259). IEEE.

Foo, Y. W., Goh, C., Lim, H. C., & Li, Y. (2015). Evolutionary Neural Network Modeling for Energy Prediction of Cloud Data Centers. Dans *International Symposium on Grids and Clouds*.

Fouladi, K., Wemhoff, A. P., Silva-Llanca, L., Abbasi, K., & Ortega, A. (2017). Optimization of data center cooling efficiency using reduced order flow modeling within a flow network modeling approach. *Applied Thermal Engineering*, 124, 929-939.

Gao, J. (2014). Machine learning applications for data center optimization.

Gao, J., & Jamidar, R. (2014). Machine learning applications for data center optimization. *Google White Paper*.

Govindan, R., Minei, I., Kallahalla, M., Koley, B., & Vahdat, A. (2016). Evolve or die: High-availability design principles drawn from googles network infrastructure. Dans *Proceedings of the 2016 ACM SIGCOMM Conference* (pp. 58-72).

Guérout, T., Monteil, T., Da Costa, G., Calheiros, R. N., Buyya, R., & Alexandru, M. (2013). Energy-aware simulation with DVFS. *Simulation Modelling Practice and Theory*, 39, 76-91.

Hamilton, J. D. (1994). *Time series analysis* (Vol. 2). Princeton New Jersey.

Hammond, S. W. (2017). *Holistic Approach to Data Center Energy Efficiency*. National Renewable Energy Lab.(NREL), Golden, CO (United States).

Hibat-Allah Ounifi, M. O., Marc Paquet. (2015, JUNE 14 - 17, 2015). *Data center location for Internet services* présentée à International Meeting Canadian Operational Research Society Institute for Operations Research and the Management Sciences, Montreal. Repéré à <https://studylib.net/doc/8105166/full-program-pdf>

Hoyer, M., Schr, K., #246, der, Schlitt, D., & Nebel, W. (2011). *Proactive dynamic resource management in virtualized data centers* présentée à Proceedings of the 2nd International Conference on Energy-Efficient Computing and Networking, New York, New York, USA. doi: 10.1145/2318716.2318719

Hsu, C., & Geng, H. (2014). Rack PDU for green data centers. *Data Center Handbook*.

- Jaureguialzo, E. (2011). PUE: The Green Grid metric for evaluating the energy efficiency in DC (Data Center). Measurement method using the power demand. Dans *2011 IEEE 33rd International Telecommunications Energy Conference (INTELEC)* (pp. 1-8). IEEE.
- Jiang, X., Jing, Z., Li, Y., Wu, Q., & Tang, W. (2014). Modelling and operation optimization of an integrated energy based direct district water-heating system. *Energy*, 64, 375-388.
- Jin, X., Zhang, F., Vasilakos, A. V., & Liu, Z. (2016). Green Data Centers: A Survey, Perspectives, and Future Directions. *arXiv preprint arXiv:1608.00687*.
- Jing, Z., Jiang, X., Wu, Q., Tang, W., & Hua, B. (2014). Modelling and optimal operation of a small-scale integrated energy based district heating and cooling system. *Energy*, 73, 399-415.
- Kant, K. (2009). Data center evolution: A tutorial on state of the art, issues, and challenges. *Computer Networks*, 53(17), 2939-2965.
- Karpati, A., Zsigmond, G., Vörös, M., & Lendvay, M. (2012). Uninterruptible Power Supplies (UPS) for data center. Dans *2012 IEEE 10th Jubilee International Symposium on Intelligent Systems and Informatics* (pp. 351-355). IEEE.
- Kontorinis, V., Zhang, L. E., Aksanli, B., Sampson, J., Homayoun, H., Pettis, E., . . . Rosing, T. S. (2012). Managing distributed ups energy for effective power capping in data centers. Dans *2012 39th Annual International Symposium on Computer Architecture (ISCA)* (pp. 488-499). IEEE.
- Krein, P. T. (2017). Data center challenges and their power electronics. *CPSS Transactions on Power Electronics and Applications*, 2(1), 39-46.
- Kulseitova, A., & Fong, A. T. (2013). A survey of energy-efficient techniques in cloud data centers. Dans *ICT for Smart Society (ICISS), 2013 International Conference on* (pp. 1-5). IEEE.
- Li, L., Zheng, W., Wang, X., & Wang, X. (2014). Coordinating liquid and free air cooling with workload allocation for data center power minimization. Dans *11th International Conference on Autonomic Computing (ICAC'14)* (pp. 249-259).
- Liu, X., Ounifi, H.-A., Gherbi, A., Li, W., & Cheriet, M. (2019). A hybrid GPU-FPGA based design methodology for enhancing machine learning applications performance. *Journal of Ambient Intelligence and Humanized Computing*, 1-15.
- Maselli, J. B., Blessington, S., & Stein, R. J. (2018). Modular data center: Google Patents.

- Michalak, S. E., Bonnie, A. M., Montoya, A. J., Storlie, C. B., Rust, W. N., Ticknor, L. O., . . . Reich, B. J. (2018). A Temperature Monitoring Infrastructure and Process for Improving Data Center Energy Efficiency with Results for a High Performance Computing Data Center. *Analytic Methods in Systems and Software Testing*, 329.
- Ndukaife, T. A., & Nnanna, A. A. (2019). Optimization of water consumption in hybrid evaporative cooling air conditioning systems for data center cooling applications. *Heat transfer engineering*, 40(7), 559-573.
- Ounifi, H.-A., Gherbi, A., Kara, N., & Li, W. (2019). A deep neural network based approach to energy efficiency analysis for cloud data center. Dans *2019 IEEE 17th International Conference on Industrial Informatics (INDIN)* (Vol. 1, pp. 1397-1404). IEEE.
- Ounifi, H.-A., Liu, X., Gherbi, A., Lemieux, Y., & Li, W. (2018). Model-based approach to data center design and power usage effectiveness assessment. *Procedia Computer Science*, 141, 143-150.
- Ounifi, H.-A., Ouhimmou, M., Paquet, M., & Montecinos, J. (2015). Datacenter location for Internet services in the province of Quebec. *IFAC-PapersOnLine*, 48(3), 2266-2272.
- Pegus II, P., Varghese, B., Guo, T., Irwin, D., Shenoy, P., Mahanti, A., . . . Hill, C. (2016). Analyzing the efficiency of a green university data center. Dans *Proceedings of the 7th ACM/SPEC on International Conference on Performance Engineering* (pp. 63-73). ACM.
- Ponsard, C., & Deprez, J.-C. (2015). A UML KPI profile for energy aware design and monitoring of cloud services. Dans *2015 10th International Joint Conference on Software Technologies (ICSOFT)* (Vol. 1, pp. 1-6). IEEE.
- Ponsard, C., Deprez, J.-C., & Michel, R. (2015). Guiding cloud developers to build energy aware applications. Dans *ICSOFT* (pp. 397-414). Springer.
- Qi, S., Zhang, Y., & Wang, M. (2019). Study and Application on Data Center Infrastructure Management System Based on Artificial Intelligence (AI) and Big Data Technology. Dans *2019 IEEE 4th International Future Energy Electronics Conference (IFEEEC)* (pp. 1-4). IEEE.
- Rasmussen, N. (2006). Electrical efficiency modeling of data centers: APC. White paper.
- Rygielski, P., Kounev, S., & Zschaler, S. (2013). Model-based throughput prediction in data center networks. Dans *2013 IEEE International Workshop on Measurements & Networking (M&N)* (pp. 167-172). IEEE.
- Sharma, P., Pegus II, P., Irwin, D., Shenoy, P., Goodhue, J., & Culbert, J. (2017). Design and operational analysis of a green data center. *IEEE Internet Computing*, 21(4), 16-24.

- Sheehan, S. (2013). PUE Calculations: Model and Myths. *CCG Whitepaper_ PUE Calculations Model and Myths*.
- Shoukourian, H., Wilde, T., Labrenz, D., & Bode, A. (2017). Using Machine Learning for Data Center Cooling Infrastructure Efficiency Prediction. Dans *2017 IEEE International Parallel and Distributed Processing Symposium Workshops (IPDPSW)* (pp. 954-963). doi: 10.1109/IPDPSW.2017.25
- Singh, U., Bhagwat, H. G., Varghese, A., Singh, A. K., Jayaprakash, R., & Sivasubramaniam, A. (2018). System and method for facilitating optimization of cooling efficiency of a data center: Google Patents.
- Snevely, R. (2002). *Enterprise data center design and methodology*. Prentice Hall Press.
- Sondur, S., Ray, M., Biswas, J., & Kant, K. (2017). Implementing data center network energy management capabilities in ns3. Dans *2017 Eighth International Green and Sustainable Computing Conference (IGSC)* (pp. 1-8). IEEE.
- Stansberry, M. (2017). Uptime institute's 2017 datacenter industry survey results: URL: [https://uptimeinstitute.com/webinars/2017_data-center ...](https://uptimeinstitute.com/webinars/2017_data-center...)
- Tarutani, Y., Hashimoto, K., Hasegawa, G., Nakamura, Y., Tamura, T., Matsuda, K., & Matsuoka, M. (2015). Temperature distribution prediction in data centers for decreasing power consumption by machine learning. Dans *2015 IEEE 7th International Conference on Cloud Computing Technology and Science (CloudCom)* (pp. 635-642). IEEE.
- Tarutani, Y., Hashimoto, K., Hasegawa, G., Nakamura, Y., Tamura, T., Matsudax, K., & Matsuoka, M. (2016). Reducing Power Consumption in Data Center by Predicting Temperature Distribution and Air Conditioner Efficiency with Machine Learning. Dans *2016 IEEE International Conference on Cloud Engineering (IC2E)* (pp. 226-227). doi: 10.1109/IC2E.2016.39
- Varga, A. (2010). OMNeT++. Dans *Modeling and tools for network simulation* (pp. 35-59). Springer.
- Varsamopoulos, S., Bertels, K., & Almudever, C. G. (2018). Designing neural network based decoders for surface codes. *arXiv preprint arXiv:1811.12456*.
- Vishal Kumar, J. G. (2016, June 26 - 30, 2016). *optimization of power usage effectiveness for heterogeneous modular data centers using neural networks* présentée à ENERGY 2016 : The Sixth International Conference on Smart Grids, Green Communications and IT Energy-aware Technologies, Lisbon, Portugal.

- Wang, L., & Khan, S. U. (2013). Review of performance metrics for green data centers: a taxonomy study. *The journal of supercomputing*, 63(3), 639-656.
- Whitted, W. H., & Aigner, G. (2007). Modular data center: Google Patents.
- Wierman, A., Liu, Z., Liu, I., & Mohsenian-Rad, H. (2014). Opportunities and challenges for data center demand response. Dans *International Green Computing Conference* (pp. 1-10). IEEE.
- Zheng, K., Zheng, W., Li, L., & Wang, X. (2017). PowerNetS: Coordinating data center network with servers and cooling for power optimization. *IEEE Transactions on Network and Service Management*, 14(3), 661-675.

